

Možnosti využití umělé inteligence při humanitárním mapování

Bc. Dominika Hajdová

Diplomová práce
2025



Univerzita Tomáše Bati ve Zlíně
Fakulta logistiky a krizového řízení

Univerzita Tomáše Bati ve Zlíně

Fakulta logistiky a krizového řízení

Ústav ochrany obyvatelstva

Akademický rok: 2024/2025

ZADÁNÍ DIPLOMOVÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení:	Bc. Dominika Hajdová
Osobní číslo:	L23033
Studijní program:	N1032A020002 Bezpečnost společnosti
Specializace:	Ochrana obyvatelstva
Forma studia:	Kombinovaná
Téma práce:	Možnosti využití umělé inteligence při humanitárním mapování

Zásady pro vypracování

- Proveďte rešerši témat pokrývajících problematiku humanitárního mapování a umělé inteligence.
- Testujte efektivitu využití umělé inteligence v humanitárním mapování.
- Analyzujte vliv kvality dat a algoritmické zaujatosti na výsledky.
- Zhodnotte výsledky analýz a diskutujte možnosti využití umělé inteligence v humanitárním mapování.

Forma zpracování diplomové práce: **tištěná/elektronická**

Seznam doporučené literatury:

1. BEDUSCHI, Ana. *Harnessing the Potential of Artificial Intelligence for Humanitarian Action: Opportunities and Risks*. *International Review of the Red Cross*, vol. 104, no. 919, 2022, pp. 1149–1169. Published by Cambridge University Press on behalf of the ICRC. doi:10.1017/S1816383122000261.
2. MENDES, Amalia, PALMER, Tess, BERENS, Andrew, ESPEY, Julie, PRICE, Rhiannan, MALLYA, Apoorva, BROWN, Sidney, MARTINEZ, Maureen, FARAG, Noha, KAPLAN, Brian. *Mapathons versus automated feature extraction: a comparative analysis for strengthening immunization microplanning*. *International Journal of Health Geographics*, 20, 27. 2021. <https://doi.org/10.1186/s12942-021-00277-x>.
3. NAJJAR, Omran. *Hot_tech_talk | fAlr: AI-assisted mapping*. 2022. <https://www.hotosm.org/tech-blog/hot-tech-talks-fair/>.
4. NGUMENAWA, Samson. *HOT's Approach to OSM Data Validation for Earthquake Response Mapping*. HOT OSM. 2023. <https://www.hotosm.org/updates/hot-approach-to-osm-data-validation-to-eq-mapping-projects/>.
5. SIRKO, Wojciech, KASHUBIN, Sergii, RITTER, Marvin., ANNKAH Abigail, BOUCHAREB, Yasser Salah Eddine, DAUPHIN, Yann, KEYSERS Daniel, NEUMANN, Maxim, CISSE, Moustapha, QUINN, John. *Continental-Scale Building Detection from High Resolution Satellite Imagery*, 2021. <https://doi.org/10.48550/arXiv.2107.12283>.

Další odborná literatura dle doporučení vedoucího práce.

Vedoucí diplomové práce: **RNDr. Jakub Trojan, MSc, Ph.D.**
Ústav environmentální bezpečnosti

Datum zadání diplomové práce: **2. prosince 2024**
Termín odevzdání diplomové práce: **25. dubna 2025**

L.S.

prof. Ing. Zuzana Tučková, Ph.D.
děkanka

prof. Ing. Dušan Vičar, CSc.
ředitel ústavu

V Uherském Hradišti dne 2. prosince 2024

PROHLÁŠENÍ AUTORA DIPLOMOVÉ PRÁCE

Beru na vědomí, že

- odevzdáním diplomové práce souhlasím se zveřejněním své práce podle zákona č. 111/1998 Sb., v platném znění bez ohledu na výsledek obhajoby;
- diplomová práce bude uložena v elektronické podobě v univerzitním informačním systému a bude dostupná k nahlédnutí;
- jedno vyhotovení diplomové práce v listinné podobě bude ponecháno Univerzitě Tomáše Bati ve Zlíně k uložení;
- na moji diplomovou práci se plně vztahuje zákon č. 121/2000 Sb. o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) ve znění pozdějších právních předpisů, zejm. § 35 odst. 3;
- podle § 60 odst. 1 autorského zákona má Univerzita Tomáše Bati ve Zlíně právo na uzavření licenční smlouvy o užití školního díla v rozsahu § 12 odst. 4 autorského zákona;
- podle § 60 odst. 2 a 3 mohu užít své dílo – diplomovou práci – nebo poskytnout licenci k jejímu využití jen s předchozím písemným souhlasem Univerzity Tomáše Bati ve Zlíně, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly Univerzitou Tomáše Bati ve Zlíně na vytvoření díla vynaloženy (až do jejich skutečné výše);
- pokud bylo k vypracování diplomové práce využito softwaru poskytnutého Univerzitou Tomáše Bati ve Zlíně nebo jinými subjekty pouze ke studijním a výzkumným účelům (tj. k nekomerčnímu využití), nelze výsledky diplomové práce využít ke komerčním účelům;
- pokud je výstupem diplomové práce jakýkoliv softwarový produkt, považují se za součást práce rovněž i zdrojové kódy, popř. soubory, ze kterých se projekt skládá; neodevzdání této součásti může být důvodem k neobhájení práce.

Prohlašuji, že

- jsem na diplomové práci pracoval(a) samostatně a použitou literaturu jsem řádně citoval(a); v případě publikace výsledků budu uveden(a) jako spoluautor;
- odevzdaná verze diplomové práce a verze elektronická nahraná do IS/STAG jsou obsahově totožné.

V Uherském Hradišti, dne 25.4.2025

.....
podpis autora

ABSTRAKT

Tato diplomová práce se zabývá evaluací možností využití umělé inteligence (AI) v humanitárním mapování. S ohledem na rostoucí potřebu efektivního mapování a monitorování oblastí postižených různými humanitárními krizemi, je zkoumáno, jak AI může přispět ke zlepšení procesů mapování a analýzy. Práce se zaměřuje na případy z praxe, a analyzuje, jak AI může posílit schopnost humanitárních organizací při mapování v postižených oblastech. Metodologie zahrnuje hodnocení současných přístupů a nástrojů AI, analýzu dat a technologií používaných v humanitárním mapování a aplikaci AI ve vybraných případech. Výsledky práce poskytují ucelený pohled na možnosti využití AI v humanitárním mapování a doporučení pro další výzkum a praxi.

Klíčová slova: humanitární mapování, umělá inteligence, fAIr, prostorová data, evaluace

ABSTRACT

This diploma thesis focuses on the evaluation of the potential of artificial intelligence (AI) in humanitarian mapping. In response to the growing need for effective crisis mapping, the study analyzes how AI tools can improve mapping accuracy, speed, and decision-making in humanitarian contexts. The work is based on practical testing of AI-assisted tools, with special focus on the open-source fAIr platform, compared to traditional manual mapping using JOSM. The thesis includes empirical experimentation, effectiveness assessment, and recommendations for future use.

Keywords: humanitarian mapping, artificial intelligence, fAIr, geospatial data, evaluation

Na tomto místě bych ráda poděkovala všem, kteří mě na cestě k této diplomové práci podporovali, motivovali a inspirovali.

Především bych chtěla vyjádřit upřímné poděkování vedoucímu mé diplomové práce RNDr. Jakubu Trojanovi, MSc, Ph.D. za odborné vedení, a podnětu k této práci, za jeho konzultace, trpělivost a vstřícnost.

Velké díky patří také Mgr. Radimu Štampachovi, Ph.D. za vedení experimentu a jeho ochotu sdílet cenné informace. Jeho vstřícný přístup, rychlá komunikace a dlouholeté zkušenosti s humanitárním mapováním byly pro mě důležitým zdrojem podpory.

Mé poděkování patří také všem účastníkům experimentu, kteří si našli čas zapojit se do testování, a pomohli tak vytvořit datový základ pro analytickou část práce. Bez jejich aktivní spolupráce by realizace experimentu nebyla možná.

Velké díky směřuje i k celému týmu Missing Maps a komunitě humanitárního mapování, jejichž aktivit jsem se mohla zúčastnit v rámci mapathonů, za sdílení praktických zkušeností, rad a tipů ze strany zkušených mapérů, které byly pro mě velmi obohacující. Tato komunita mi poskytla důležitý kontext i motivaci k hlubšímu zájmu o mapování a krizovou geografii.

Zvláštní poděkování patří také mému zaměstnavateli, který mi umožnil flexibilní pracovní režim, díky kterému jsem mohla studium a výzkum zvládat i při pobytu v zahraničí. Vážím si důvěry, podpory a porozumění, které jsem po celou dobu cítila.

V neposlední řadě bych chtěla poděkovat své rodině, příteli a blízkým přátelům za jejich neustálou podporu, trpělivost a povzbuzení. Děkuji, že jste při mně stáli nejen v náročných chvílích psaní práce, ale i v průběhu celého studia. Vaše víra ve mě a schopnost mě rozesmát, i když jsem už sama sebe brala moc vážně, pro mě byly nenahraditelné.

Tato práce vznikla i díky vám všem!

OBSAH

ÚVOD.....	11
CÍL PRÁCE.....	12
I TEORETICKÁ ČÁST	13
1 NADPIS HLAVNÍ KAPITOLY	14
1.1 HUMANITÁRNÍ MAPOVÁNÍ A JEHO VÝZNAM	15
1.1.1 Mapathon.....	16
1.2 VYUŽITÍ UMĚLÉ INTELIGENCE V MAPOVÁNÍ A GIS	17
1.2.1 Mapování objektů pomocí AI	19
1.3 POROVNÁNÍ GLOBÁLNÍCH A LOKÁLNÍCH AI MODELŮ.....	21
1.4 ETICKÉ ASPEKTY VYUŽITÍ AI V HUMANITÁRNÍCH AKTIVITÁCH	22
1.5 PŘEHLED SOUČASNÝCH NÁSTROJŮ PRO HUMANITÁRNÍ MAPOVÁNÍ.....	23
1.5.1 fAIr.....	23
1.5.2 iD Editor.....	25
1.5.3 RapiD	26
1.5.4 JOSM.....	27
1.6 NÁSTROJE VYVÍJENÉ TECHNOLOGICKÝMI KORPORACEMI.....	30
1.6.1 Microsoft	30
1.6.2 Meta.....	31
1.6.3 Overture maps	33
2 DÍLČÍ ZÁVĚR	35
II PRAKTICKÁ ČÁST	36
3 ZAMĚŘENÍ PRAKTICKÉ ČÁSTI.....	37
4 TESTOVANÉ NÁSTROJE	38
4.1 fAIr.....	38
4.1.1 Obecný popis mapování s fAIr	38
4.1.2 Mapování během experimentu	43
4.2 JOSM.....	44
4.2.1 Instalace JOSM	45
4.2.2 Instalace pluginů	45
4.2.3 Načítání území	47
4.2.4 Mapování v JOSM	47
4.2.5 Ukládání dat	49
5 METODIKA	50
5.1 CÍLE A HYPOTÉZY	50
5.2 TESTOVACÍ PROSTŘEDÍ.....	50
5.3 FORMA TESTOVÁNÍ.....	51
5.4 ÚČASTNÍCI	51

5.4.1	Participantů.....	52
5.5	VYMEZENÍ LOKALIT	53
5.6	SCÉNÁŘE	54
5.7	HODNOCENÍ DLE ISO-NORMY	55
5.8	STATISTICKÉ VYHODNOCENÍ VÝSLEDKŮ.....	56
5.9	PRŮBĚH EXPERIMENTU	57
5.9.1	Průběh mapování.....	58
5.9.2	Dotazníkové šetření.....	60
5.9.3	Export a validace dat	61
5.9.4	Vyhodnocení mapovaných dat	61
5.9.5	Kritéria vyhodnocování.....	62
6	ANALÝZA A VÝSLEDKY	64
6.1	HODNOCENÍ EFEKTIVITY MAPOVÁNÍ.....	64
6.2	HODNOCENÍ ÚČINNOSTI MAPOVÁNÍ	65
6.3	SROVNÁNÍ PODLE ÚROVNĚ ZKUŠENOSTI	66
6.4	SROVNÁNÍ PODLE NÁROČNOSTI OBLASTI	67
6.5	STATISTICKÁ ANALÝZA VÝSLEDKŮ	69
6.5.1	Testování normality dat.....	69
6.5.2	Testování statistických rozdílů.....	69
6.5.3	Statistické porovnání nástrojů podle úrovně zkušenosti	70
6.6	ANALÝZA CHYB MAPOVÁNÍ.....	73
6.7	HODNOCENÍ SPOKOJENOSTI	74
6.8	SHRNUTÍ ANALYTICKÝCH ZJIŠTĚNÍ	77
7	DISKUSE.....	79
	ZÁVĚR.....	81
	SEZNAM POUŽITÉ LITERATURY	83
	SEZNAM OBRÁZKŮ	89
	SEZNAM TABULEK.....	90
	SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK	91
	SEZNAM PŘÍLOH.....	92

ÚVOD

V současné době svět čelí narůstajícímu počtu humanitárních krizí různého charakteru od přírodních katastrof přes ozbrojené konflikty až po důsledky klimatických změn. Tyto události kladou vysoké nároky na schopnost rychlé a efektivní reakce humanitárních organizací a státních institucí. Jedním z předpokladů účinné pomoci je dostupnost aktuálních a přesných prostorových informací o postižených oblastech. Mapování těchto oblastí hraje zásadní roli při identifikaci potřeb obyvatelstva, koordinaci zásahů a distribuci zdrojů.

S rozvojem technologií, zejména v oblasti umělé inteligence (AI), se objevují nové možnosti pro zefektivnění procesu mapování. AI umožňuje automatizaci vybraných kroků, zrychlení zpracování dat a zlepšení detekce prostorových objektů, což může zásadně ovlivnit způsob, jakým jsou krizové situace mapovány a analyzovány.

Tato diplomová práce se zaměřuje na evaluaci možností využití AI v humanitárním mapování. Cílem je posoudit, do jaké míry může AI přispět ke zlepšení přesnosti a rychlosti tvorby prostorových dat a jaké jsou limity jejího praktického nasazení v krizovém kontextu. Konkrétně je analyzován open-source nástroj fAIr, který umožňuje trénování lokálních AI modelů pro automatické mapování budov, a jeho výstupy jsou porovnány s tradičním ručním mapováním v editoru JOSM.

Úvodní kapitoly práce poskytují přehled o vývoji humanitárního mapování, specifikách využití AI v geografických informačních systémech a nástrojích používaných v této oblasti. Následuje popis metodologie, která kombinuje experimentální přístup s kvantitativním i kvalitativním vyhodnocením. Výsledky analýzy jsou následně interpretovány s důrazem na praktické využití a doporučení pro budoucí aplikace a výzkum v oblasti AI asistovaného humanitárního mapování.

CÍL PRÁCE

Cílem této diplomové práce je analyzovat možnosti a limity využití nástrojů založených na umělé inteligenci v kontextu humanitárního a dobrovolnického mapování. Hlavní pozornost je věnována nástroji fAIr, který využívá strojové učení k predikci prostorových objektů z leteckých a satelitních snímků. Jeho výstupy budou porovnány s daty získanými prostřednictvím manuální editace v prostředí JOSM.

Výzkum je strukturován jako experimentální srovnání obou nástrojů s využitím dvou základních výkonnostních metrik:

- účinnost, definovaná jako míra přesnosti zmapovaných objektů,
- efektivita, chápána jako rychlost mapování vyjádřená počtem správně zmapovaných budov za jednotku času.

Experimentu se zúčastní dobrovolníci s různou úrovní mapovacích zkušeností, přičemž testování proběhne na geograficky rozličných lokalitách s cílem zachytit vliv složitosti území na kvalitu výstupů. Výsledky budou sloužit k formulaci doporučení pro praktické nasazení AI nástrojů v rámci krizového řízení, komunitního mapování i školení nových přispěvatelů. Na základě dosavadních poznatků byly stanoveny následující hypotézy:

- H1: fAIr umožní mapovat budovy rychleji než JOSM.
- H2: fAIr nabídne srovnatelnou nebo vyšší přesnost než JOSM.

Prostřednictvím ověření těchto hypotéz chce práce přispět k lepšímu porozumění možnostem využití umělé inteligence při mapování budov, zejména s ohledem na efektivitu a přesnost výstupů v kontextu humanitárního mapování a zároveň naznačit potenciál nástrojů s podporou AI pro budoucí zefektivnění mapovacích procesů v humanitárním sektoru

I. TEORETICKÁ ČÁST

1 NADPIS HLAVNÍ KAPITOLY

Humanitární mapování hraje zásadní roli při koordinaci a distribuci pomoci v oblastech postižených přírodními katastrofami, konflikty nebo jinými krizovými situacemi. Díky němu lze rychle identifikovat nejvíce zasažené oblasti, stanovit priority zásahů a efektivně řídit distribuci zdrojů (HAKLAY, 2010). Tradiční metody mapování založené na manuálním zpracování geografických dat jsou však často pomalé a náročné na zdroje, což omezuje jejich využití v krizových situacích. S příchodem umělé inteligence (AI) se tento proces zásadně mění.

Umělá inteligence umožňuje automatizaci mnoha úkolů spojených s mapováním a geografickými informačními systémy (GIS). Mezi klíčové přínosy AI patří schopnost rychle analyzovat velké objemy dat, identifikovat klíčové geografické prvky a předpovídat vývoj krizových situací. Například konvoluční neuronové sítě (CNN) umožňují rozpoznávat objekty na satelitních snímcích, jako jsou budovy, silnice, vegetace nebo vodní plochy, což je klíčové pro rychlé a přesné zmapování postižených oblastí (ZHU et al., 2017).

Projekty jako Humanitarian OpenStreetMap Team (HOT) využívají AI pro rychlou aktualizaci map na základě analýzy dat získaných ze satelitních snímků. Nástroje jako RapiD nebo fAIr umožňují dobrovolníkům a odborníkům kombinovat manuální mapování s automatizovanými analýzami. RapiD, vyvinutý společností Meta ve spolupráci s HOT, automaticky identifikuje silnice a budovy, čímž značně urychluje proces mapování (NAJJAR, 2022).

Další pokročilé nástroje, jako je Segment Anything Model (SAM) nebo Yolov8, přispívají k přesnější extrakci geografických dat, zejména v komplexních a obtížně dostupných regionech. Tento přístup byl úspěšně aplikován při mapování oblastí postižených zemětřesením nebo povodněmi, kdy byla potřeba rychlá reakce (MENDES et al., 2021).

Jednou z klíčových otázek při implementaci AI v humanitárním mapování je volba mezi globálními a lokálními modely. Globální AI modely, trénované na rozsáhlých mezinárodních datech, často selhávají v přesnosti při aplikaci v specifických regionech s unikátními geografickými podmínkami. Naproti tomu lokální modely, trénované na regionálně specifických datech, dosahují vyšší přesnosti a lepší přizpůsobení místním podmínkám (SIRKO et al., 2021).

Projekt fAIr je příkladem nástroje, který umožňuje lokální trénink AI modelů. Tyto modely jsou schopny lépe reagovat na potřeby konkrétních komunit a zvýšit přesnost mapování kritických oblastí, což je klíčové zejména v krizových situacích s vysokou dynamikou.

Zavedení AI do humanitárního mapování přináší nejen výhody, ale také nové výzvy a etické otázky. Algoritmická zaujatost, způsobená nekvalitními nebo nekompletními daty, může vést k nesprávným rozhodnutím a neefektivním zásahům. Transparentnost AI modelů je dalším kritickým aspektem, neboť uživatelé musí rozumět rozhodovacím procesům a být schopni identifikovat možné chyby (BEDUSCHI, 2022).

Další výzvou je ochrana citlivých dat. V krizových situacích může být manipulace s geografickými a osobními údaji zneužita, což klade vysoké nároky na zabezpečení systémů. Humanitární organizace proto musí implementovat robustní standardy ochrany dat a odpovědně spravovat získané informace (OBERMEYER a EMANUEL, 2016).

Umělá inteligence má potenciál zásadně zlepšit humanitární mapování, zejména díky inovacím v oblasti strojového učení, analýzy velkých dat a prediktivního modelování. Vývoj pokročilých algoritmů, jako je transfer learning, umožňuje jemné doladění AI modelů na regionální data, což zvyšuje jejich efektivitu a přesnost (SHAH, O. a TALLAM, K., 2023).

Humanitární mapování je klíčovým nástrojem při řešení krizových situací, a díky pokročilým technologiím AI se jeho efektivita a přesnost neustále zlepšují. Projekty, jako je fAIr nebo RapiD, ukazují, že kombinace lokálních a globálních přístupů může přinést optimální výsledky. Etické a technické výzvy však vyžadují další výzkum a vývoj, aby bylo možné plně využít potenciál AI a zajistit, že bude sloužit potřebám zranitelných komunit. Umělá inteligence tak představuje klíčový prvek budoucího humanitárního mapování, s cílem poskytovat rychlejší a přesnější pomoc tam, kde je to nejvíce potřeba.

1.1 Humanitární mapování a jeho význam

Humanitární mapování představuje zásadní součást humanitárních operací, které poskytuje nezbytné informace pro plánování a koordinaci pomoci v oblastech postižených přírodními katastrofami, konflikty či jinými krizovými situacemi. Tento proces zahrnuje sběr, analýzu a vizualizaci geografických dat, což umožňuje humanitárním organizacím identifikovat postižené oblasti, stanovit priority zásahů a efektivně distribuovat pomoc. Dobrovolníci z celého světa, často zapojení prostřednictvím otevřených platforem jako OpenStreetMap

(OSM), vytvářejí mapy těchto postižených oblastí. Tento přístup umožňuje rychlou aktualizaci map a poskytování přesných dat potřebných pro koordinaci záchranných a humanitárních operací.

Humanitární organizace jako Mezinárodní červený kříž, Lékaři bez hranic nebo Organizace spojených národů (OSN) často spoléhají na moderní mapovací technologie a geografické informační systémy (GIS). GIS umožňuje nejen přesné zmapování postižených oblastí, ale i plánování logistické podpory, evakuací a distribuce humanitární pomoci. Mapovací data mohou zahrnovat informace o zničené infrastruktuře, přístupových trasách a dalších klíčových prvcích, které usnadňují rozhodovací procesy v reálném čase (HAKLAY, 2010).

Jedním z nejvýznamnějších projektů v této oblasti je Humanitarian OpenStreetMap Team (HOT), který organizuje síť dobrovolníků po celém světě. Tento projekt usiluje o rychlou aktualizaci geografických dat v krizových oblastech a jejich poskytnutí humanitárním organizacím pro účely operativního řízení. Data generovaná HOT často kombinují manuální mapování s automatizovanými nástroji, včetně těch, které využívají umělou inteligenci (AI) pro rozpoznávání objektů na satelitních snímcích (HUMANITARIAN OPENSTREETMAP TEAM, 2024).

Umělá inteligence hraje čím dál důležitější roli v humanitárním mapování, jelikož umožňuje rychlejší a přesnější zpracování obrovského množství geografických dat. AI nástroje, jako je například projekt fAIr, zlepšují schopnost humanitárních pracovníků rychle analyzovat a reagovat na měnící se situace v terénu, což má zásadní význam zejména při krizových událostech s vysokou dynamikou (NAJJAR, 2022).

1.1.1 Mapathon

Mapathon představuje formu dobrovolnické aktivity, jejímž cílem je zlepšování geografických dat v oblastech, kde buď zcela chybí mapové podklady, nebo nejsou dostatečně aktuální a přesné. Během těchto událostí účastníci společně pracují nad satelitními snímky, na jejichž základě do otevřené mapové platformy OpenStreetMap (OSM) doplňují prostorové informace, jako jsou budovy, komunikace nebo jiné klíčové infrastruktury. Typicky se jedná o území zasažená přírodními katastrofami, ozbrojenými konflikty či jinými krizovými situacemi, kde aktuální mapové podklady slouží jako nezbytný nástroj pro humanitární zásahy a rozvojovou pomoc.

Myšlenka mapathonů se vyvíjela souběžně s projektem OpenStreetMap, založeným v roce 2004 jako otevřená databáze prostorových dat dostupná široké veřejnosti (HAKLAY & WEBER, 2008). Zásadní impuls pro rozvoj kolektivního mapování přišel v roce 2010 po zemětřesení na Haiti, kdy se dobrovolníkům z celého světa podařilo během několika dní vytvořit podrobnou mapu postižených oblastí, což významně usnadnilo práci záchranným složkám (ZOOK et al., 2010). Tato zkušenost poukázala na potenciál dobrovolnického mapování a stála u zrodu organizace Humanitarian OpenStreetMap Team (HOT), která se následně začala systematicky věnovat koordinaci mapovacích akcí v humanitárním kontextu.

Mapathony jsou dnes pořádány v různých formátech, jak prezenčně, tak online, a to jak neziskovými organizacemi (např. HOT, Missing Maps), tak univerzitami či firemními týmy. Společným cílem je generovat relevantní prostorová data pro potřeby organizací působících v terénu, například Lékařů bez hranic, kteří tato data využívají při plánování očkovacích kampaní, analýze dostupnosti zdravotní péče či logistice krizových operací. Akce jsou otevřené i pro veřejnost bez předchozí zkušenosti; účastníci jsou během mapathonu vedeni instruktory, kteří je seznamují s principy mapování a nástroji používanými pro práci v OSM prostředí (OPENSTREETMAP WIKI CONTRIBUTORS, 2024).

V posledních letech dochází k postupné automatizaci mapování, a to díky zavádění technologií umělé inteligence a strojového učení. Moderní přístupy, jako je např. využití editoru RapiD, umožňují předem vygenerovat mapové prvky (např. budovy a komunikace) na základě AI modelů, přičemž úkolem dobrovolníků je následná kontrola a validace těchto predikcí. Tento postup šetří čas a zvyšuje celkovou účinnost mapování, jelikož mapéři se mohou soustředit na verifikaci údajů namísto ručního zakreslování všech prvků. V důsledku toho dochází k rozšíření dostupnosti kvalitních prostorových dat i v oblastech, které byly dosud geograficky opomíjeny.

1.2 Využití umělé inteligence v mapování a GIS

Umělá inteligence (AI) stále více proniká do oblasti geografických informačních systémů (GIS) a mapování, kde přináší významné inovace a zlepšení v oblasti efektivity, přesnosti a rychlosti zpracování geografických dat. AI umožňuje automatizaci řady úkolů, které byly dříve prováděny ručně, a tím výrazně urychluje proces mapování, zejména v krizových situacích nebo při mapování rozsáhlých oblastí.

Jedním z přínosů AI v GIS je její schopnost automatizované detekce objektů na satelitních a leteckých snímcích. Pomocí metod, jako jsou konvoluční neuronové sítě (CNN) a další techniky hlubokého učení, mohou AI modely rozpoznávat a klasifikovat objekty, jako jsou budovy, silnice, vegetace či vodní plochy. Tento přístup se používá například v humanitárních projektech zaměřených na rychlé zmapování oblastí postižených přírodními katastrofami nebo konflikty (ZHU et al., 2017).

Například v projektu Omdena se využívají pokročilé AI modely, jako je Segment Anything Model (SAM) a YOLOv8, které umožňují přesnější extrakci geografických prvků z obrazových dat. Tyto modely excelují v detekci objektů i v komplexních geografických prostředích, čímž významně přispívají k rychlejší aktualizaci map a efektivnějšímu plánování humanitárních operací. Mendes et al. (2021) uvádějí, že automatizované metody, jako je extrakce prvků založená na AI, dokážou výrazně zkrátit dobu potřebnou k mapování a současně zvýšit přesnost při rozpoznávání objektů, což je klíčové zejména v krizových situacích.

Na tyto přístupy navazují další inovativní využití AI, která se stále častěji uplatňují v analýze geografických dat v reálném čase. Tato schopnost zpracovávat data téměř okamžitě zlepšuje možnosti organizací rychle reagovat na změny v terénu. Projekty, jako jsou fAIr nebo RapiD, využívají AI k automatizovanému mapování a umožňují tak efektivní analýzu velkých objemů dat s minimálními požadavky na manuální zásahy. Díky těmto technologiím mohou humanitární pracovníci rychleji identifikovat kritické oblasti a efektivněji plánovat své operace, což zásadně zvyšuje jejich schopnost reagovat na krizové situace (HUMANITARIAN OPENSTREETMAP, 2022).

Další oblastí, kde AI přináší výrazné zlepšení, je prediktivní modelování v GIS. Pomocí AI mohou analytici lépe předpovídat, jak se bude vyvíjet situace v určitých geografických oblastech. Například při monitorování klimatických změn nebo urbanizace mohou být AI modely trénovány na historických datech a na základě toho předpovídat budoucí změny krajiny či vývoj katastrofických událostí, jako jsou povodně nebo lesní požáry (GOODCHILD, 2020).

AI také výrazně zlepšuje možnosti crowdsourcingu v mapování. Platformy, jako je Tomnod, kombinují sílu AI a dobrovolníků k analýze satelitních snímků, kde AI modely pomáhají identifikovat klíčové oblasti zájmu a dobrovolníci pak potvrzují nebo korigují výsledky, čímž se zvyšuje přesnost map (NGUMENAWA, 2023).

Zavádění AI do GIS a mapování však přináší také nové výzvy, zejména v oblasti etických otázek a závislosti na kvalitě dat. AI modely jsou závislé na kvalitních tréninkových datech, a pokud jsou tato data neúplná nebo zkreslená, mohou modely produkovat nepřesné nebo zaujaté výsledky. Důležitým aspektem je proto zajištění transparentnosti a odpovědného používání AI při rozhodovacích procesech v rámci mapovacích projektů (OBERMEYER a EMANUEL, 2016).

1.2.1 Mapování objektů pomocí AI

Manuální mapování vyžaduje značné množství času, pozornosti a zkušeností, aby bylo možné správně interpretovat satelitní snímky a odlišit mapované objekty od okolních prvků. Tento proces je obzvláště náročný v oblastech s hustou zástavbou, nepravidelnými strukturami nebo nízkou kvalitou snímků, například v některých částech rozvojového světa.

AI technologie, jako je hluboké učení, umožňují analýzu satelitních a leteckých snímků a automatické generování obrysů budov či tras. Modely umělé inteligence jsou trénovány na rozsáhlých datových sadách a dokážou efektivně rozpoznávat vzory a tvary objektů, což vede k výraznému zrychlení mapovacího procesu.

1.2.1.1 Detekce budov

Hlavním úkolem humanitárního mapování je detekce budov na základě satelitních snímků, které umožňuje efektivní identifikaci a analýzu urbanistických struktur v krizových oblastech. Společnost Microsoft vyvinula automatizované zpracování geografických dat implementací pokročilých metod hlubokého učení (deep learning) pro přesnější detekce půdorysů budov.

Hlavním využívaným nástrojem pro detekci budov byl Microsoft Cognitive Toolkit (CNTK), což je open-source sada nástrojů určená k modelování neuronových sítí prostřednictvím orientovaných grafů, která umožňovala implementaci různých typů hlubokých neuronových sítí (Deep Neural Networks), přičemž v kontextu detekce budov byly tyto modely kombinovány s moderními technikami strojového učení. Je však třeba poznamenat, že CNTK je nyní považován za zastaralý a jeho vývoj byl ukončen (GITHUB, 2020).

Důležitým přístupem k detekci budov je použití konvoluční neuronové sítě ResNet34, která se specializuje na extrakci charakteristických rysů z obrazových dat. ResNet34

disponuje hlubokou architekturou, která umožňuje rozpoznání složitých struktur budov i v různorodém terénu.

Pro dosažení vyšší přesnosti a minimalizaci chyb v detekci je ResNet34 často doplňována zpřesňující sítí RefineNet, jež umožňuje detailní segmentaci budov a jejich oddělení od okolních objektů. Tato kombinace neuronových sítí zajišťuje přesnější definování půdorysů budov, čímž se snižuje riziko chybné klasifikace nebo spojování několika samostatných struktur do jednoho objektu.

Celý proces detekce budov probíhá na základě satelitních snímků poskytovaných službou Bing Maps, oficiální mapovací platformou společnosti Microsoft (MICROSOFT, 2021). Díky integraci těchto snímků s pokročilými algoritmy strojového učení lze výrazně zrychlit a zpřesnit mapování budov v oblastech s nedostatečnými nebo zastaralými geografickými daty. Například v roce 2018 společnost Microsoft uvolnila 130 milionů půdorysů budov ve Spojených státech jako otevřená data, čímž podpořila iniciativy jako OpenStreetMap (MICROSOFT, 2018).

Detekce půdorysů budov z leteckých snímků je kompletním procesem, který lze rozdělit do dvou hlavních fází:

- **Sémantická segmentace:** Tato fáze zahrnuje analýzu obrazových dat za účelem klasifikace jednotlivých pixelů do předdefinovaných kategorií, jako jsou budovy, silnice nebo vegetace. Využívají se při tom hluboké konvoluční neuronové sítě, které se učí rozpoznávat specifické vzory a textury charakteristické pro různé objekty. Výsledkem je segmentační mapa, kde jsou pixely reprezentující budovy odlišeny od ostatních tříd.
- **Polygonizace:** Po získání segmentační mapy následuje převod detekovaných oblastí budov z rastrového formátu do vektorového tvaru, konkrétně do podoby polygonů. Tento krok zahrnuje identifikaci hranic jednotlivých budov a jejich reprezentaci pomocí vrcholů a hran. Moderní přístupy využívají grafové neuronové sítě k přesné extrakci polygonálních tvarů budov, čímž zajišťují vysokou přesnost a realistické obrysy detekovaných struktur

Budoucí vývoj v oblasti detekce budov bude pravděpodobně zaměřen na zdokonalování stávajících metod strojového učení a rozšiřování datových sad pro trénink modelů. Implementace pokročilých technik, jako je transfer learning, umožní efektivní adaptaci modelů na nové geografické podmínky. Kromě toho je třeba zajistit větší transparentnost a

přístupnost těchto technologií, aby byly dostupné pro širší spektrum uživatelů a komunit (MA et al., 2024).

1.3 Porovnání globálních a lokálních AI modelů

V posledních letech bylo realizováno několik výzkumů a projektů, které se zaměřují na využití umělé inteligence (AI) v oblasti humanitárního mapování. Tyto studie se často soustředí na aplikaci strojového učení a neuronových sítí k automatické analýze obrazových dat získaných z družicových snímků a terénních fotografií (QUINN et al., 2018). Kromě toho některé projekty zkoumají možnosti využití AI k identifikaci zranitelných oblastí a predikci rizik spojených s přírodními katastrofami (BEDUSCHI, 2022). Výsledky těchto studií naznačují, že AI může významně zvýšit efektivitu humanitárního mapování. Zároveň se však ukazují i výzvy spojené s kvalitou dat, interpretací výstupů a potřebou dalšího výzkumu a vývoje metodik (BEDUSCHI, 2022).

Jedním z klíčových problémů ve výzkumu je otázka, zda globální AI modely, které jsou trénovány na velkých objemech mezinárodních dat, mohou dosahovat stejně dobrých výsledků jako modely, které jsou specificky trénovány na lokálních datech. Globální modely často narazí na problémy, když jsou aplikovány v regionech, kde se podmínky výrazně liší od těch, na kterých byly modely původně trénovány. To je způsobeno zejména kulturními a environmentálními rozdíly mezi regiony (OMDENA, 2022).

Ve své studii Sirko et al. (2021) analyzovali možnosti detekce budov na kontinentálním měřítku pomocí satelitních snímků. Výsledky ukázaly, že globální modely, trénované na velkých datech z různých oblastí, často nejsou schopny přesně rozpoznat objekty v regionech s unikátními geografickými a klimatickými podmínkami. Tato zjištění vedla k vývoji nástrojů, jako je fAIr, které umožňují komunitám trénovat lokální AI modely. Tyto modely jsou přizpůsobeny specifickým podmínkám regionu, což výrazně zlepšuje jejich přesnost a efektivitu (GITHUB, 2024).

Na základě těchto výzkumů lze dospět k závěru, že zatímco globální modely jsou vhodné pro širokospektrální analýzy, v humanitárním mapování, které vyžaduje přesná a rychlá data pro specifické oblasti, jsou lokálně trénované modely výhodnější. Lokální AI modely, jako je fAIr, umožňují komunitám mapovat jejich prostředí s větší přesností, což zvyšuje efektivitu humanitárních zásahů.

1.4 Etické aspekty využití AI v humanitárních aktivitách

Ačkoli umělá inteligence (AI) přináší řadu inovativních příležitostí pro humanitární sektor, je zároveň důležité zohlednit i etické výzvy, které se objevují při jejím nasazení v krizových situacích. Jednou z hlavních výzev je potenciální algoritmická zaujatost nebo zkreslení dat, což může vést k nesprávným rozhodnutím a neefektivním zásahům v humanitárních operacích. Algoritmy trénované na nekompletních či zaujatých datech mohou například nesprávně identifikovat prioritní oblasti nebo nedostatečně reflektovat potřeby marginalizovaných komunit (PIZZI, ROMANOFF a ENGELHARDT, 2021).

Kvalita dat je podstatným faktorem ovlivňujícím výkon AI v humanitárních aktivitách. Jak upozorňuje Beduschi (2022), nedostatečná nebo neúplná data mohou vést k chybám při rozhodování a ovlivnit výsledky AI systémů. To je obzvláště problematické v krizových situacích, kde je třeba rychle a přesně analyzovat dostupné zdroje informací (TULANE UNIVERSITY, 2023). Další významnou výzvou je algoritmická transparentnost, která vyžaduje, aby byly AI systémy nejen efektivní, ale i srozumitelné pro jejich uživatele. Nedostatek transparentnosti může způsobit, že rozhodnutí AI budou působit jako „černá skříňka“, což snižuje důvěru v jejich výsledky a vyvolává otázky o odpovědnosti při chybných výstupech.

Důležitým etickým přístupem při vývoji a nasazení AI nástrojů, jako je projekt fAIr, je zapojení lokálních komunit do procesu vývoje. Lokální obyvatelé by měli být nejen pasivními příjemci výsledků AI analýz, ale také aktivními účastníky v trénování a kalibraci modelů. To zajistí, že výsledky budou lépe reflektovat skutečné potřeby regionu a nebudou založeny pouze na univerzálních, technokratických řešeních, která neberou v úvahu místní specifika (BEDUSCHI, 2022).

Technologická závislost a bezpečnost dat jsou další významné etické problémy. V krizových situacích může být závislost na složitých technologiích problémová, pokud dojde k technickým selháním nebo pokud nejsou dostupné dostatečné technologické zdroje. Zároveň je nezbytné zajistit ochranu citlivých dat, která AI systémy analyzují, aby nedošlo k jejich zneužití nebo narušení soukromí zranitelných populací (INTERNATIONAL COMMITTEE OF THE RED CROSS, 2024)

Z těchto důvodů je důležité, aby byl vývoj AI technologií doprovázen důkladnými etickými standardy a přístupem, který kombinuje technologickou inovaci s respektováním potřeb místních komunit a důrazem na lidská práva.

1.5 Přehled současných nástrojů pro humanitární mapování

Humanitární mapování se rychle vyvíjí s příchodem pokročilých technologií, zejména umělé inteligence. Ačkoli je vývoj AI programů a algoritmů často veden komerčními zájmy, do kterých směřují rozsáhlé finanční investice (INVESTORS, 2025), existují projekty zaměřené na využití AI ve prospěch společnosti.

Humanitární mapování těží z technologií, jako je AI a crowdsourcing, které umožňují organizacím lépe reagovat na krizové situace, plánovat operace a efektivně distribuovat pomoc. Společnosti jako Microsoft a Meta významně přispívají k této oblasti; Microsoft se zaměřuje na mapování budov a Meta na mapování cest. Nově se přidávají i další technologické firmy, například Amazon, což ukazuje rostoucí zájem o využití AI v dobrovolnickém mapování.

Tyto nástroje poskytují organizacím schopnost efektivněji reagovat na krizové situace, rychleji plánovat humanitární operace a lépe koordinovat distribuci pomoci, díky efektivní tvorbě geografických dat. Níže jsou uvedeny nejvýznamnější nástroje, které jsou v současné době používány.

1.5.1 fAIr

Projekt fAIr, který se od počátku roku 2023 nachází ve fázi vývoje, představuje revoluční přístup k humanitárnímu mapování. Tento projekt navazuje na iniciativu organizace HOT z roku 2020 zaměřenou na sémantickou segmentaci budov ze satelitních snímků (HOTSM, 2024a).

Hlavní organizací za tímto projektem je Humanitarian OpenStreetMap Team (HOT), která působí v oblasti dobrovolnického a humanitárního mapování. Záměrem projektu fAIr je vytvořit open-source model strojového učení, který umožní jednotlivým komunitám, obcím či zemím vytvořit si vlastní přizpůsobené modely pro mapování specifických lokalit. Akronym fAIr odkazuje na principy „freedom“ (svoboda), „Artificial Intelligence“ (umělá inteligence) a „responsibility“ (zodpovědnost), které tvoří základní hodnoty projektu.

Vývojáři projektu se zaměřili na řešení tří hlavních problémů spojených s AI modely používanými v současnosti, jako je dostupnost modelů, zaujatost trénovacích dat a chybějící zpětná vazba uživatelů (HOTSM, 2024b).

Hlavním problémem je omezená dostupnost AI modelů. Většina existujících řešení není poskytována jako otevřený kód, protože vývojáři je chrání kvůli konkurenčním výhodám a komerčním zájmům. Nedostatek transparentnosti a možnosti lokálního přizpůsobení představuje překážku pro menší komunity, které by chtěly využívat AI pro mapování svých oblastí.

Druhým problémem je zaujatost modelů, která vychází z omezené variability trénovacích dat. Pokud jsou vstupní data nevyvážená nebo pocházejí pouze z určitých geografických oblastí, může docházet k systematickým nepřesnostem při identifikaci budov a cest.

Třetím výzvou je nedostatek zpětné vazby mezi uživateli a vývojáři. Mnoho AI modelů neumožňuje snadnou úpravu nebo hlášení chyb ze strany koncových uživatelů. Tento nedostatek komunikace zpomaluje iterativní vylepšování modelů a jejich přizpůsobení specifickým potřebám. Projekt fAIr zavádí mechanismy pro aktivní spolupráci mezi komunitami, umožňující uživatelům sdílet zpětnou vazbu přímo s vývojáři.

Projekt si klade za cíl snížit závislost HOT na technologických gigantech, jako jsou Microsoft a Meta, jejichž modely byly dosud dominantním nástrojem pro generování mapových podkladů v humanitárních projektech. Implementací open-source řešení umožní fAIr demokratizaci AI mapování a poskytne nástroje, které budou přístupné i menším organizacím a komunitám (HOTOSM, 2024c). Na rozdíl od plně automatizovaných mapovacích systémů není cílem projektu fAIr masová produkce prostorových dat, nýbrž umožnění lokálním komunitám vytvářet mapové podklady odpovídající jejich specifickým potřebám.

1.5.1.1 Open Aerial Map (OAM) datové podklady

Projekt fAIr využívá jako primární datový zdroj snímky pořízené bezpilotními leteckými prostředky (UAV), které jsou zpřístupňovány prostřednictvím platformy OpenAerialMap (OAM). Jedná se o otevřenou databázi, která umožňuje přístup k aktuálním a detailním leteckým snímkům s volně dostupnou licencí. Tato data pocházejí z různorodých zdrojů, včetně komunitních iniciativ, nevládních organizací či jednotlivých operátorů UAV, kteří je pořizují zejména v krizových nebo geograficky nedostatečně pokrytých oblastech (HUMANITARIAN OPENSTREETMAP TEAM, 2024).

Výhodou využívání OAM v rámci humanitárního mapování je snadná dostupnost a otevřený charakter dat, který umožňuje jejich přímé využití nejen pro účely krizového řízení, ale i pro přípravu komunit na potenciální mimořádné události. Platforma zároveň poskytuje uživatelům možnost nahrávat vlastní datové sady a sdílet je s ostatními členy mapovací komunity. Tím vzniká prostor pro efektivní kolaboraci mezi piloty dronů operujícími v terénu a mapéry pracujícími vzdáleně.

V rámci projektu fAIr slouží tyto snímky jako vstup pro algoritmy strojového učení, které generují návrhy prostorových prvků, zejména budov a komunikací. Uživatelé následně tyto predikce validují a rozhodují o jejich začlenění do databáze OpenStreetMap (OSM). Cílem projektu není masová produkce dat, ale cílené naplňování specifických potřeb lokálních komunit, které často čelí nedostatku kvalitních kartografických podkladů.

Je však třeba zmínit také určitá omezení. Mezi nejčastější problémy patří proměnlivá kvalita a deformace snímků získaných z UAV. Tyto nedostatky mohou negativně ovlivnit výslednou přesnost predikce a komplikovat vizuální ověřování identifikovaných objektů. Přesto zůstává využití OAM jedním z klíčových prvků inovativních mapovacích přístupů v prostředí, kde jiné zdroje prostorových dat nejsou dostupné.

1.5.2 iD Editor

iD Editor je oficiální webový editor určený pro přímou editaci dat OpenStreetMap (OSM) prostřednictvím internetového prohlížeče. Byl vyvinut jako intuitivní a uživatelsky přívětivé prostředí, které umožňuje začátečníkům i pokročilejším uživatelům přispívat do projektu OSM bez nutnosti instalace specializovaného softwaru.

Editor je dostupný na adrese <https://www.openstreetmap.org/edit> a funguje po přihlášení pomocí OSM účtu. Nabízí základní nástroje pro kreslení bodů, linií a polygonů, umožňuje přidávání atributových značek a práci s podkladovými mapami. Uživatel může editovat jak stávající objekty, tak přidávat nové prvky, včetně budov, komunikací, vodních ploch nebo zájmových bodů (POI) (OPENSTREETMAP WIKI CONTRIBUTORS, 2024a).

Jednou z vlastností iD Editoru je přímá integrace s databází OSM, díky čemuž se provedené úpravy ukládají okamžitě po jejich potvrzení. Rozhraní editoru je vybaveno kontextovou nápovědou, která uživatele provází jednotlivými kroky mapování. iD Editor také nabízí možnost přepínání mezi různými mapovými podklady (např. Bing, Esri, Maxar), čímž usnadňuje vizuální identifikaci prvků (INASAFE DOCUMENTATION, 2023).

Vzhledem ke své jednoduchosti je iD Editor doporučován především začínajícím uživatelům nebo pro rychlé editace menšího rozsahu. Jeho funkce jsou však omezené ve srovnání s desktopovými nástroji jako je JOSM, zejména co se týče pokročilých funkcí, práce s relacemi nebo možnosti rozšíření pomocí pluginů. Přesto zůstává nejpřístupnější variantou pro první seznámení s editací OSM a je často využíván při mapathonech a komunitních mapovacích aktivitách (LEARNOSM, 2019).

1.5.3 RapiD

Vedle iD Editoru byl vyvinut nástroj RapiD, který přináší automatizaci do procesu mapování. Editor RapiD byl vytvořen společností Meta jako open-source rozšíření široce používaného iD editoru pro OpenStreetMap (OSM), která kombinuje výsledky modelu s existujícími daty z OSM. Tento postup eliminuje riziko vzniku duplicitních dat a zároveň poskytuje mapérům asistenci při propojení cest generovaných AI s existujícími prvky v OpenStreetMap (BASU et al., 2019). S rostoucím množstvím zobrazených prvků však editor RapiD brzy narazil na své výpočetní limity. V reakci na tento problém společnost Meta v srpnu 2022 oznámila vývoj nové verze editoru, označené jako RapiD 2.0, která měla přinést zásadní zlepšení rychlosti a plynulosti práce. Ve stejném měsíci byla zpřístupněna alpha verze tohoto editoru, která umožnila uživatelům testovat jeho nové funkce a poskytovat zpětnou vazbu ve formě připomínek a návrhů na další vylepšení (CLARK, 2022).

V dubnu 2023 byla uvedena do provozu finální verze editoru. Společnost Meta editor přejmenovala z „RapiD“ na „Rapid 2.0“ a představila novou webovou platformu, na které je editor dostupný: <https://rapideditor.org/edit>. Podle společnosti Meta je Rapid 2.0 až desetkrát rychlejší než jeho předchozí verze, což umožňuje mapování s vyšší úrovní detailu a přesnosti. Nová verze editoru rovněž podporuje práci s větším přiblížením, což je zásadní při úpravách rozsáhlých městských oblastí.

Popisky prvků byly optimalizovány tak, aby zjednodušily orientaci uživatelů a usnadnily proces mapování. Rapid 2.0 také přináší rozšířenou podporu integrace externích datových sad od různých poskytovatelů, což umožňuje přidávání podrobných atributů, například adresních bodů, k vytvořeným mapovým prvkům.

Další verze Rapid 2.5 vyšla v prosinci 2024. Editor je rozšířen o podporu pro import a editaci komplexních atributů mapových objektů a zvyšuje interoperabilitu s dalšími platformami, jako je Mapillary, čímž umožňuje detailnější vizuální informace přímo v editoru. Mezi vylepšení patří přesnější nástroje pro úpravu geometrie a pokročilé možnosti

validace dat, což z Rapid 2.5 činí komplexní a rychlý nástroj vhodný jak pro humanitární mapování, tak pro pokročilé plánování městských oblastí (BEDDOW a TRIPATHI, 2023).

RapiD nejenže umožňuje manuální validaci dat, ale také zvyšuje efektivitu práce mapérů tím, že kombinuje strojově generované návrhy s uživatelským vstupem. Tento přístup pomáhá propojit nově vytvořené prvky s již existujícími a optimalizovat celkový mapovací proces (BASU et al., 2019).

1.5.3.1 ESRI datové sady

Společnost Esri se v posledních letech aktivně zapojila do tvorby mapových podkladů prostřednictvím integrace otevřených datových sad do editoru RapiD a JOSM. Tato spolupráce umožňuje využívání vysoce přesných datasetů pocházejících z Esri ArcGIS API, přičemž v současné době jsou podporovány dvě hlavní kategorie: budovy a adresní body. Tyto datové sady nejsou generovány umělou inteligencí, ale pocházejí z různých autoritativních zdrojů, včetně místních samospráv a vládních organizací.

Díky aktualizaci uživatelského rozhraní RapiD si nyní uživatelé mohou tyto vrstvy zvolit k zobrazení a editaci stejným způsobem jako jiné mapové prvky. Výhodou je také možnost slučování adresních bodů s existujícími budovami, čímž se výrazně zvyšuje datová přesnost v OpenStreetMap.

S rozvojem editoru RapiD lze očekávat postupnou implementaci dalších otevřených datových sad, což rozšíří možnosti mapování i do dalších regionů po celém světě.

1.5.4 JOSM

JOSM (Java OpenStreetMap Editor) je bezplatný desktopový software určený pro editaci geografických dat v prostředí OpenStreetMap (OSM). První beta verze editoru byla vyvinuta v roce 2005 Immanuelem Scholzem, přičemž plná verze editoru je od srpna 2018 spravována Dirkiem Stöckerem. Aplikace je implementována v programovacím jazyce Java, což umožňuje multiplatformní provoz na systémech Windows, Linux i macOS. Software je dostupný ve více než 30 jazykových mutacích a lze jej bezplatně stáhnout z oficiálních stránek josm.openstreetmap.de (OPENSTREETMAP CONTRIBUTORS, 2024b).

JOSM je komplexní editor umožňující rozmanité typy úprav a editací, přičemž nabízí široké spektrum funkcí, které z něj činí univerzální nástroj pro práci s daty OpenStreetMap. Umožňuje import a práci s různými datovými formáty, jako jsou GPX (formát GPS), letecké

snímky či mapové služby typu WMS (Web Map Service), TMS (Tile Map Service) nebo WMTS (Web Map Tile Service). Díky těmto možnostem lze snadno integrovat předem stažené podklady OSM, které jsou dále editovatelné přímo v rozhraní editoru. Podpora více kartografických projekcí a práce s vrstvami umožňuje přizpůsobit editor specifickým potřebám projektu. Mezi jeho klíčové vlastnosti patří i editace vztahů, aplikace filtrů pro efektivní správu dat, přednastavení stylů či jejich vykreslování. Tyto funkce jsou doplněny o možnosti mapování prostřednictvím fotografií nebo dokonce hlasem, což výrazně zvyšuje flexibilitu a uživatelskou přívětivost editoru (JOSM, 2024a). Ačkoliv může uživatelské rozhraní JOSM působit na první pohled komplikovaně, jeho ovládání je možné si rychle osvojit díky více než 200 dostupným klávesovým zkratkám.

JOSM vyniká svou širokou funkcionalitou. Umožňuje import a práci s různými datovými formáty, jako jsou GPX a GeoJSON, a podporuje zobrazování leteckých snímků, vrstev OSM či dat z externích služeb typu WMS, TMS a WMTS. Editor umožňuje práci s vrstvami, různými kartografickými projekcemi a poskytuje nástroje pro editaci vztahů, použití filtrů, nastavování stylů a jejich vizualizaci. Specifickými funkcemi jsou možnosti mapování na základě fotografií nebo pomocí hlasového vstupu (JOSM, 2024a).

Jednou z předností editoru je možnost rozšíření jeho funkcionality prostřednictvím tzv. pluginů. V současnosti je k dispozici 186¹ oficiálně podporovaných pluginů, které uživatelům umožňují rozšířit editor o další nástroje. Tyto rozšiřující moduly přidávají funkce, které nejsou součástí základní verze editoru. Umožňují například snadnější vykreslování budov, přidávání odkazů nebo práci s daty v 3D prostředí. Dalšími výhodami jsou téměř neomezené možnosti přiblížení pro detailní mapování, rychlá oprava chyb a pravidelná aktualizace editoru, která každý měsíc přináší nové funkce a zlepšení (JOSM, 2024b). Nejčastěji využívaným pluginem při mapování budov je Buildings Tools, který usnadňuje kreslení pravoúhlých či kruhových budov. Pokročilí uživatelé mají možnost pracovat manuálně a vytvářet složitější struktury odpovídající specifickým geometrickým požadavkům.

Uživatelské rozhraní JOSM může působit zpočátku neintuitivně, nicméně editor disponuje více než 200 klávesovými zkratkami, které usnadňují navigaci a zvyšují efektivitu práce. Editace dat probíhá lokálně a změny jsou nahrány do databáze OpenStreetMap až po explicitním potvrzení uživatelem. V projektech, jako je Missing Maps, procházejí tyto

¹ stav k 10. 1. 2025, verze JOSM 19277

úpravy kontrolou validátorů. Při standardní editaci v OSM probíhá validace pouze na žádost autora.

Editor JOSM si získal popularitu zejména mezi zkušenými editory a komunitou humanitárního mapování, a to díky jeho stabilitě a pluginům. K jeho přednostem patří nejen rozšiřitelnost a pravidelné aktualizace, ale také vysoká stabilita, flexibilita a možnost pokročilé práce s daty na úrovni jednotlivých prvků mapy (JOSM, 2024b).

Vývoj editoru JOSM probíhá jako otevřený komunitní projekt. Tato open-source architektura umožňuje zapojení dobrovolníků z celého světa, kteří se podílejí na jeho vylepšování, testování i přidávání nových funkcí. Transparentnost vývoje přispívá k důvěryhodnosti editoru, zatímco jeho nezávislost na komerčních licencích je výhodná zejména v humanitárním kontextu, kde je dostupnost a udržitelnost softwaru zásadní (JOSM, 2024c).

Editor JOSM je hojně využíván rovněž pro účely validace dat v rámci humanitárních projektů, jako je Missing Maps. Validátoři zde využívají pokročilé funkce editoru k ověřování správnosti geometrie, atributových údajů a topologických vztahů, což zajišťuje konzistenci a kvalitu mapových výstupů, které slouží jako podklad pro rozhodování v krizových situacích.

Navzdory výhodám, které JOSM nabízí, nelze opomenout ani některé jeho limity. Uživatelské rozhraní editoru může působit zpočátku nepřehledně a může představovat překážku zejména pro začátečníky bez předchozí zkušenosti s GIS nástroji. Vyšší vstupní náročnost je potřeba zohlednit zejména při školení nových dobrovolníků, kterým je vhodné poskytnout instruktážní podporu nebo alternativní nástroje pro první mapovací úkoly. zejména mezi zkušenými editory a komunitou humanitárního mapování. K jeho přednostem patří nejen rozšiřitelnost a pravidelné aktualizace, ale také vysoká stabilita, flexibilita a možnost pokročilé práce s daty na úrovni jednotlivých prvků mapy (JOSM, 2024b).

1.5.4.1 Pluginy

Známé také jako zásuvné moduly jsou neoddělitelnou součástí editoru JOSM, neboť umožňují jeho funkční rozšíření a přizpůsobení editoru konkrétním potřebám uživatele. Jejich instalace probíhá přímo z prostředí programu nebo skrze oficiální web editoru. Většina pluginů je vyvíjena komunitně v jazyce Java, což zajišťuje otevřenost a flexibilitu jejich vývoje. Před instalací je nezbytné ověřit kompatibilitu s aktuální verzí editoru, neboť starší verze mohou vykazovat nestabilitu nebo chyby (JOSM, 2024c).

Pluginy umožňují mimo jiné pokročilé kreslení budov, interaktivní 3D vizualizace, přidávání specifických atributů či pracovní záznamy. Časté jsou také moduly podporující export dat, automatickou validaci, nebo propojení s externími mapovými službami. Pluginový systém tak zajišťuje škálovatelnost editoru JOSM a jeho adaptabilitu pro různé typy humanitárních i odborných mapovacích účelů.

1.6 Nástroje vyvíjené technologickými korporacemi

1.6.1 Microsoft

Na konci listopadu 2021 byl Microsoft označen za nejhodnotnější společnost na světě, čímž předčil svého dlouholetého konkurenta Apple (FORBES, 2021). Tento úspěch byl důsledkem trvalého růstu v oblastech cloud computingu, digitálních služeb a softwarových technologií. V následujících letech společnost intenzivně investovala do rozvoje technologií umělé inteligence (AI), strojového učení (ML) a počítačového vidění, které se staly klíčovými oblastmi jejího výzkumu a aplikací.

V kontextu mapování a geografických informačních systémů (GIS) se Microsoft zaměřil na vývoj nástrojů, které automatizují analýzu geografických dat a zpracování satelitních snímků. Klíčovým příkladem této práce je projekt AI for Earth, který integruje AI pro lepší pochopení a ochranu přírodních ekosystémů (MICROSOFT, 2018). V rámci tohoto projektu byly vyvinuty pokročilé algoritmy pro analýzu obrazových dat, které umožňují automatickou detekci a vykreslení půdorysů budov na základě satelitních snímků.

Jedním z hlavních příspěvků Microsoftu v oblasti humanitárního mapování je vývoj nástroje RapiD, který byl vytvořen ve spolupráci s Humanitarian OpenStreetMap Team a společností Meta (dříve Facebook). Tento nástroj využívá AI pro automatizované mapování kritických oblastí. RapiD umožňuje rychlé identifikování budov a silnic a jejich přidávání do platformy OpenStreetMap (OSM). Zpracování dat prostřednictvím AI zvyšuje přesnost mapování a snižuje nutnost manuální editace, což je klíčové při reakcích na humanitární krize, jako jsou přírodní katastrofy nebo konflikty (BING MAPS TEAM, 2020).

Microsoft se také zaměřuje na zlepšení přístupnosti a kvality mapovacích dat prostřednictvím využití cloudových služeb Azure. Tyto služby umožňují zpracovávat obrovské objemy geografických dat v reálném čase a poskytovat je organizacím, které je mohou využívat při plánování humanitárních operací. Podle Mendes et al. (2021) přispěly

technologie Microsoftu k rozšíření možností humanitárního mapování, zejména díky schopnosti analyzovat geografická data rychleji a s vyšší přesností.

Navzdory těmto pokrokům čelí Microsoft kritice týkající se závislosti na proprietárních technologiích a možného omezení transparentnosti, což jsou klíčové otázky pro komunitu OpenStreetMap a humanitární organizace. Tyto obavy vedly k vývoji alternativních nástrojů, jako je fAIr, které podporují lokální trénink AI modelů a odklon od velkých korporací, čímž zajišťují větší transparentnost a nezávislost mapovacích procesů (HUMANITARIAN OPENSTREETMAP TEAM, 2023).

1.6.2 Meta

Společnost Meta Platforms Inc., dříve známá jako Facebook, patří mezi přední globální technologické korporace, jejichž aktivity přesahují rámec správy a rozvoje sociálních sítí, jako jsou Facebook, Instagram a WhatsApp. V posledních letech Meta významně investuje do výzkumu a vývoje umělé inteligence (AI), přičemž její aplikace sahají od personalizace obsahu a rozpoznávání obrazu až po geografické mapování.

Jedním z významných počínů společnosti Meta v oblasti AI pro mapování je iniciativa "Map with AI", jejímž cílem je usnadnit a urychlit proces mapování silnic, cest a dalších geografických prvků prostřednictvím strojového učení. Tento projekt byl navržen na podporu komunity OpenStreetMap (OSM), umožňující dobrovolníkům efektivněji aktualizovat a doplňovat geografická data s využitím nástrojů poháněných AI. V rámci této iniciativy Meta vyvinula editor Rapid (dříve známý jako RapiD), což je rozšířená verze editoru iD, která integruje pokročilé mapovací nástroje, autoritativní geoprostorová otevřená data a nejmodernější technologie.

AI modely analyzují satelitní snímky a na základě rozpoznaných vzorců detekují silnice a další infrastrukturní prvky. Projekt využívá konvoluční neuronové sítě (CNN), jež umožňují identifikaci vzorců na satelitních snímcích a detekci cest a komunikací. Tento proces je doplněn post-processing algoritmy, které pomáhají filtrovat chybně detekované objekty a optimalizují přesnost výsledných mapových vrstev. Další významnou součástí je transfer learning, jenž umožňuje přizpůsobení AI modelů různým geografickým oblastem. Tato metoda eliminuje potřebu trénovat modely od základu a umožňuje efektivní aplikaci stávajících poznatků na nové regiony. Uživatelé tak mohou snadněji schvalovat, upravovat nebo odmítat AI-generované návrhy, čímž dochází ke kombinaci automatizace a lidské

expertizy, což urychluje celý proces mapování a zároveň zajišťuje kontrolu kvality ze strany zkušených editorů OSM.

Meta plánuje další rozšíření, jednou z plánovaných funkcionalit je detailnější analýza povrchu komunikací, která by AI umožnila rozlišovat různé typy cest, například asfaltové, šterkové nebo polní. Další oblastí zlepšení je přesnější detekce v různých geografických regionech. Současné modely budou dále trénovány na širším spektru dat, aby mohly lépe reflektovat lokální podmínky a zajistit vyšší přesnost výsledků. V budoucnosti by se také mohla rozšířit detekce dalších prvků v mapách, například budov, mostů či jiných infrastrukturálních prvků. Tento přístup by umožnil rozšíření využití AI v komunitním mapování a zefektivnil by práci dobrovolníků a organizací využívajících OpenStreetMap.

1.6.2.1 Map with AI

Před oficiálním spuštěním projektu Map With AI prošly nástroje společnosti Meta důkladným testováním v různých geografických a humanitárních kontextech. Jedním z prvních významných projektů bylo mapování silniční infrastruktury v Thajsku. Tým Mety se zaměřil na více než 480 000 km dosud nezmapovaných cest v rámci OpenStreetMap. Za pomoci umělé inteligence se tento úkol podařilo dokončit během 18 měsíců, což je výrazně rychleji, než by zvládl tým 100 zkušených mapérů, kteří by na stejný objem dat potřebovali přibližně dvojnásobek času (GAO, KLAIBER a UNDERWOOD, 2019).

Ještě před thajským projektem byla technologie Map With AI nasazena v Malawi. Mapování zde mělo klíčovou roli při plánování očkovací kampaně Červeného kříže proti spalničkám a zarděnkám. Pomocí AI se podařilo automaticky vyfiltrovat 97 % neobydleného území, čímž se mapéři mohli zaměřit na zbylá 3 % terénu, kde bylo identifikováno více než 100 000 obydlí, což výrazně usnadnilo plánování zásahů a návštěv prioritních oblastí (META, 2019).

Technologie Map With AI využívá pro segmentaci cest konvoluční neuronové sítě určené pro sémantickou segmentaci satelitních snímků. Tento postup umožňuje přesně odlišit cesty od okolních prvků, jako jsou vegetace, budovy nebo prázdné plochy. Výsledkem segmentace je rastrová vrstva, kde je pravděpodobnost výskytu cesty vizualizována pomocí odstínů barev – nejvyšší pravděpodobnost odpovídá jasně rozpoznatelným cestám, zatímco nižší hodnoty indikují méně zřetelné oblasti.

Pro tento účel Meta implementovala upravenou verzi architektury D-LinkNet, která byla speciálně navržena pro detekci liniových struktur, jako jsou silnice (ZHOU, ZHANG a WU, 2018). Tato síť umožňuje zpracování rozsáhlých oblastí a zároveň vykazuje vysokou přesnost i v případech snížené kvality snímků či nepravidelné infrastruktury. Po dokončení segmentace následuje proces vektorizace, během něhož jsou rastrová data převedena na vektorovou síť. Tento výstup lze následně porovnat s existujícími daty v OpenStreetMap, což usnadňuje identifikaci chybějících úseků a jejich následnou aktualizaci (BASU et al., 2019).

Vedle detekce cest zahrnuje Map With AI také nástroje pro rozpoznávání budov. Tento proces je postaven na hlubokém učení a využívá rozsáhlé tréninkové sady zahrnující různé typy a tvary budov. Modely jsou trénovány tak, aby dokázaly identifikovat obrysy staveb na základě vizuálních charakteristik střech, a to jak u pravidelných, tak i u nepravidelných struktur. Výsledkem je sada polygonů reprezentujících obydlí, která je následně validována komunitou mapérů. Tato manuální kontrola slouží k ověření správnosti a geografické přesnosti výstupu. V závěrečné fázi dochází k optimalizaci dat; slučování blízkých segmentů, odstranění duplicitních prvků a standardizace tvarů tak, aby byl výstup co nejpřesnější a prakticky využitelný.

1.6.3 Overture maps

Overture Maps je projekt zahájený v roce 2022 pod záštitou Linux Foundation², jehož cílem je vytvořit otevřenou a interoperabilní mapovou platformu s vysokou kvalitou dat. Iniciativa vznikla ve spolupráci s předními technologickými firmami, včetně Amazonu, Microsoftu, společnosti Meta a poskytovatele navigačních služeb TomTom (LINUX FOUNDATION, 2023). Hlavním cílem této iniciativy je snížit závislost na komerčně dominantních mapových službách, jako je Google Maps, a nabídnout otevřenou alternativu (TEACHCRUNCH, 2022). Projekt má být orientovaný hlavně na shromažďování rozsáhlých geografických dat s cílem vytvořit otevřenou a interoperabilní mapovou platformu. V rámci této iniciativy plánuje spolupracovat s organizacemi, jako je OpenStreetMap (OSM), aby integroval komunitou vytvořená data a na jejich základě vytvářel vlastní datové sady dostupné pod otevřenou licencí (OVERTURE MAPS FOUNDATION, 2023).

² Linux Foundation - je neziskové technologické konsorcium, založené za účelem podpory rozvoje Linuxu (Linux Foundation, 2023)

Společnost TomTom, jako jeden ze zakládajících členů projektu, přináší do Overture Maps své bohaté zkušenosti v oblasti mapovacích služeb. Ačkoli její předchozí mapové aplikace nezaznamenaly výrazný průlom, spolupráce s Overture Maps a neomezený přístup k rozsáhlým datovým zdrojům jí umožní vyvinout novou mapovou aplikaci. Tato aplikace by měla zahrnovat funkce jako navigaci, poskytování dopravních informací, vyhledávání a vizualizaci dat, což posílí její konkurenceschopnost na trhu s mapovými službami (TOMTOM, 2022).

Pro subjekty, které mají zájem aktivně se podílet na rozvoji projektu Overture Maps a přispívat svými daty, je k dispozici systém členství s různými úrovněmi zapojení. Nejvyšší úroveň členství vyžaduje roční příspěvek ve výši 3 miliony dolarů, zatímco základní úroveň je dostupná zdarma, avšak s omezeným vlivem na směřování projektu (OVERTURE MAPS FOUNDATION, 2024)

2 DÍLČÍ ZÁVĚR

Současný vývoj v oblasti umělé inteligence a geografického mapování ukazuje významný posun směrem k automatizaci a efektivitě zpracování prostorových dat. Technologické inovace, jako jsou Map with AI, nebo AI for Earth od společnosti Meta a další iniciativy podporované Microsoftem demonstrují praktické využití AI pro humanitární a environmentální účely. Zvláštní pozornost je v této souvislosti věnována nástrojům Map with AI a RapiD, které kombinují automatizované prediktivní modely s uživatelskou validací v prostředí OpenStreetMap (OSM). Tento přístup nejen urychluje proces mapování, ale také zvyšuje kvalitu a přesnost získaných dat, což je důležité pro humanitární organizace a krizový management. Meta tímto způsobem přispívá ke zlepšení dostupnosti prostorových informací, které jsou využívány při plánování zásahů v oblastech postižených katastrofami. Oba nástroje tak představují inovativní příklady hybridního přístupu, které mohou významně přispět k optimalizaci pracovních toků při krizovém mapování.

Zvlášť důležitým poznatkem je rozdíl v efektivitě mezi globálními a lokálními AI modely. Jak bylo doloženo v řadě empirických studií, globální modely, byť trénované na rozsáhlých datech, vykazují omezenou přenositelnost a v některých geografických kontextech selhávají při detekci specifických objektů. Oproti tomu lokálně doškolené modely prokazují významně vyšší míru přesnosti, neboť reflektují regionální specifika, jakými jsou typologie zástavby, materiálové struktury či kontextuální uspořádání prostorových entit.

Z teoretických poznatků dále vyplývá, že technologický pokrok v oblasti AI s sebou nese i významné etické a datové výzvy. Otázky algoritmické zaujatosti, nízké transparentnosti modelů a nedostatečné robustnosti datových vstupů jsou považovány za potenciální rizika, které mohou vést k chybným rozhodnutím při krizovém zásahu. Z tohoto důvodu je nezbytné zdůraznit důslednou datovou validaci, otevřenost modelů a zapojení místních aktérů nejen jako cílových uživatelů, ale i jako aktivních spoluautorů tréninkových sad.

II. PRAKTICKÁ ČÁST

3 ZAMĚŘENÍ PRAKTICKÉ ČÁSTI

Navazující praktická část této diplomové práce je věnována empirickému ověření možnosti využití nástrojů založených na umělé inteligenci při humanitárním mapování. Na základě poznatků z teoretické části je zde podrobně popsán průběh experimentálního testování nástrojů fAIr a JOSM, přičemž cílem je zjistit, do jaké míry mohou AI asistované přístupy nahradit nebo doplnit tradiční manuální mapování.

Kapitola [4] nejprve představuje zvolené nástroje, přibližuje jejich funkce a způsob použití v kontextu humanitárního mapování. Kapitola [5] se věnuje metodologii experimentu; od návrhu výzkumu, přes výběr účastníků až po sběr a analýzu dat. Následující analytická část v kapitole [6] shrnuje výsledky testování a porovnání výkonnostních metrik mezi testovanými nástroji.

Cílem této části je nejen kvantifikovat výkonnost jednotlivých nástrojů, ale i identifikovat jejich vhodnost pro různé typy uživatelů a mapovacích situací. Praktická část tak poskytuje důležitý základ pro závěrečné zhodnocení potenciálu umělé inteligence v oblasti humanitárního mapování.


4 TESTOVANÉ NÁSTROJE

4.1 fAIr

Nástroj fAIr je webová aplikace dostupná bez instalace přímo v internetovém prohlížeči na adrese <https://fair.hotosm.org/>. Je vyvíjena organizací Humanitarian OpenStreetMap Team jako experimentální platforma pro testování využití umělé inteligence při mapování budov v OpenStreetMap. Pro práci v prostředí fAIr není třeba žádná lokální instalace, postačuje připojení k internetu a běžný webový prohlížeč. Uživatel se přihlašuje prostřednictvím svého účtu OpenStreetMap.

4.1.1 Obecný popis mapování s fAIr

V první části musí mít uživatel založený účet u Open Street Maps (OSM) přes odkaz <https://www.openstreetmap.org/> a následně se skrz platformu fAIr <https://fair-dev.hotosm.org/> přihlásí.




Obrázek 1. Úvodní stránka fAIr

(zdroj: fAIr, 2025)

Po úspěšném přihlášení se uživateli zobrazí hlavní pracovní prostředí nástroje fAIr, kde může zahájit proces mapování skrz „start mapping“, kde si zvolí předtrénovaný AI model.

fAIr AI models

Each model is trained using one of the training datasets. Published models can be used to find mappable features in imagery that is similar to the training areas that dataset comes from.

[+ CREATE MODEL](#)

Obrázek 2. Výběr AI modelových úloh

(zdroj: fAIr, 2025)

Nástroj umožňuje uživatelům vytvářet také vlastní tréninkové datasety („create model“), které se využívají pro vylepšení stávajících AI modelů

Uživatel začíná označením tréninkových oblastí na základě satelitních snímků, které odpovídají zájmové lokalitě. Tyto oblasti musí zahrnovat různé typy budov a jejich hustoty, aby byl trénink modelu co nejkomplexnější.

Training Area



Obrázek 3. Trénovací oblast pro AI

(zdroj: fAIr, 2025)

4.1.1.1 Proces mapování a úpravy parametrů

Před spuštěním predikce je důležité nastavit odpovídající úroveň přiblížení mapy. Doporučuje se pracovat s hodnotami mezi 19 a 21, které odpovídají standardům manuálního mapování. Tato úroveň přiblížení umožňuje přesné rozeznávání objektů, přičemž při nižších hodnotách by mohlo docházet k horší detekovatelnosti budov.

Podstatnou částí mapovacího procesu je dále práce s konfiguračním oknem „Config“, které umožňuje přizpůsobit parametry predikčního modelu. Toto okno se nachází v pravé části uživatelského rozhraní a slouží k nastavení hodnot, jako je tolerance tvarů, minimální plocha detekovaných objektů nebo pravděpodobnost detekce. Po úpravě parametrů je možné spustit proces predikce budov stisknutím tlačítka „Run Prediction“.

Po aktivaci predikce trvá několik vteřin (obvykle 10 až 40 vteřin, v závislosti na aktuálním vytížení platformy), než model vygeneruje obrysy budov. Tyto obrysy, zvýrazněné fialovou barvou, představují tvary budov detekované umělou inteligencí (viz Obrázek 4. Testování generovaných objektů

(zdroj: fAIr, 2025)4.).



Obrázek 4. Testování generovaných objektů

(zdroj: fAIr, 2025)

Pokud jsou vygenerované obrysy v souladu se skutečným tvarem budov na snímku, uživatel může jednotlivé budovy ručně potvrdit kliknutím na příslušný objekt a výběrem možnosti „Accept“ (viz. Obrázek 5. Konfigurační okno s výchozími hodnotami,

(zdroj: fAIr, 2025)

). Po potvrzení všech správně detekovaných budov lze pokračovat na další část snímku a spustit predikci znovu.



Obrázek 5. Konfigurační okno
s výchozími hodnotami,

(zdroj: fAIr, 2025)

V případech, kdy predikce není dostatečně přesná, je možné upravit parametry v konfiguračním okně „Config“ (na obrázku č. 5) nebo změnit úroveň přiblížení mapy. Poté lze znovu spustit predikci a generovat alternativní variantu obrysů budov. Nejčastěji se upravují následující parametry:

4.1.1.2 Nastavení:

Pro optimalizaci mapování vzhledem ke specifickým požadavkům daného území mají uživatelé možnost upravit klíčové parametry, jako jsou tolerance tvarů, pravděpodobnost detekce (confidence) nebo minimální velikost objektu (area).

- **Confidence (Pravděpodobnost detekce):** Tento parametr stanovuje minimální práh spolehlivosti, který musí být splněn, aby systém označil objekt jako budovu. Vyšší hodnoty zajišťují vyšší přesnost predikce, jelikož eliminují méně spolehlivé výsledky, avšak zároveň mohou vést k vynechání některých relevantních objektů. Pokud je tato hodnota nastavena příliš vysoko, model bude přesnější, ale některé budovy nemusí být detekovány. Proto se doporučuje ponechat výchozí nastavení.
- **Tolerance (Tolerance tvarů):** Udává míru vyhlazení obrysů budov a je definována jako přibližná vzdálenost mezi dvěma uzly v polygonu. Nižší hodnota poskytuje detailnější a přesnější výsledky, což je vhodné zejména pro oblasti s nepravidelnými nebo složitými tvary budov. Vyšší nastavení naopak zjednodušuje obrysy objektů a pomáhá eliminovat drobné nesrovnalosti, čímž snižuje šum v datech. Volba optimální hodnoty závisí na charakteru mapovaného území – nižší tolerance je ideální pro přesné zakreslení

komplexních struktur, zatímco vyšší tolerance je výhodná v oblastech s jednodušší urbanistickou strukturou.

- **Area (Minimální plocha objektu):** Definuje nejmenší možnou velikost detekovaného objektu, který bude považován za budovu. Tento parametr pomáhá eliminovat nežádoucí prvky, například stromy nebo malé přístřešky, které by mohly být mylně klasifikovány jako budovy.

Výběr a nastavení těchto parametrů závisí na individuálním testování a přizpůsobení konkrétní situaci. Pokud se v různých částech mapovaného území vyskytují budovy odlišných velikostí a tvarů, mohou být v jednotlivých částech snímku optimální různá nastavení parametrů. Dále je třeba zohlednit, že kvalita navržených obrysů budov může být ovlivněna úrovní přiblížení mapy, což může vyžadovat další úpravy parametrů pro dosažení nejlepších výsledků (fAIr tutorial)

4.1.1.3 Validace a export dat

Po vygenerování obrysů budov poskytuje platforma možnost jejich manuální validace. Tento proces zahrnuje kontrolu správnosti tvaru a polohy budov s cílem zajistit, že žádné objekty nejsou nesprávně spojeny nebo naopak rozděleny na více částí. Validovaná data lze následně exportovat ve formátu GeoJSON, který zajišťuje kompatibilitu s analytickými a vizualizačními softwary, jako jsou GIS platformy, nebo nástroje pro prostorovou analýzu.

4.1.2 Mapování během experimentu

4.1.2.1 Načtení území

V rámci experimentu byl každému účastníkovi přidělen unikátní odkaz, jehož prostřednictvím se otevřela konkrétní mapovací oblast v editoru fAIr. Tato oblast odpovídala lokalitám předem stanoveným pro testování a byla nastavena organizátorem experimentu. Po kliknutí na odkaz došlo k načtení konkrétního území se satelitním snímkem a předgenerovanými predikcemi budov vytvořenými modelem strojového učení.

Načtená oblast obsahovala obvykle desítky až stovky polygonů znázorňujících detekované budovy. Tyto objekty bylo možné jednotlivě označit a posoudit, zda odpovídají reálné zástavbě. Editor fAIr umožňuje práci v prostředí připomínajícím běžné mapovací nástroje, včetně zoomování, posunu a výběru objektů. Ovládání je plně intuitivní, bez nutnosti technické konfigurace nebo zásahů do systému.

4.1.2.2 Mapování v prostředí fAIr

Vlastní mapování ve fAIr probíhalo formou schvalování nebo ignorování předem detekovaných objektů. Po načtení oblasti mohl uživatel jednotlivé budovy potvrdit kliknutím na „Yes“, případně odmítnout volbou „No“. Každý záznam byl evidován a ukládán lokálně v rámci relace přihlášeného uživatele.

Aplikace fAIr neumožňuje v aktuální verzi ruční editaci geometrie ani přidávání nových objektů. Z toho důvodu spočíval hlavní úkol účastníků experimentu ve validaci predikovaných budov. Při schvalování je doporučeno postupovat důsledně a zaměřovat se zejména na tvarovou přesnost, polohovou správnost a kontext objektu (např. jestli se opravdu jedná o budovu, nikoli stín, vegetaci apod.).

Rozhraní fAIr pracuje s jednoduchou grafikou a rozděluje mapovací plochu do jednotlivých úloh (tzv. „tasks“), mezi nimiž může uživatel přecházet. Při každém záznamu editor ukládá metadata o zvolených možnostech. Přesnost predikce se lišila dle charakteru zástavby, kvality podkladového snímku a složitosti urbanistické struktury.

4.1.2.3 Ukládání a odevzdání dat

V rámci experimentu nebylo cílem odesílat data přímo do OpenStreetMap, ale shromáždit výstupy pro následnou analýzu. Po dokončení mapování účastník kliknul na tlačítko „Download“, kterým si stáhl výsledek mapování ve formátu GeoJSON. Tento soubor obsahoval informace o všech objektech, které byly v dané relaci potvrzeny jako budovy.

Uživatelé byli požádáni, aby výstupní soubor pojmenovali dle svého uživatelského jména na OSM a uložili jej lokálně. Následně byl tento soubor odeslán organizátorům experimentu prostřednictvím předem určeného kanálu (např. e-mail, formulář), kde sloužil jako podklad pro statistické vyhodnocení a porovnání výkonnosti mezi nástroji.

4.2 JOSM

Editor JOSM byl v rámci experimentální části této diplomové práce využit jako nástroj pro manuální editaci dat OpenStreetMap. Účastníci experimentu měli za úkol zpracovat přidělené mapovací úlohy, které spočívaly ve vektorizaci budov na základě satelitních

snímků. Všichni účastníci byli před zahájením testování obeznámeni s prostředím editoru a bylo jim poskytnuto metodické školení, případně přístup k instruktážním materiálům.

Pro účely testování byly v JOSM aktivovány specifické nástroje a pluginy, především Buildings Tools, který umožňuje efektivní kreslení pravoúhlých struktur. V rámci některých úloh účastníci využili i pokročilejší funkce editoru, jako je práce s vrstvami, kontrola geometrie či validace topologie. Editor JOSM umožnil přesné digitální zakreslení obrysů budov, přičemž důraz byl kladen na jejich tvarovou věrnost a konzistenci s podkladovými snímky.

Součástí záznamu každé mapovací úlohy byla také informace o čase zpracování a počtu zmapovaných objektů, které následně sloužily jako podklad pro hodnocení účinnosti (počet budov za minutu) a efektivity (procento správně zmapovaných budov). Výsledky editací byly validovány zkušeným kontrolorem a porovnány s výstupy ze stejné oblasti vytvořenými pomocí nástroje fAIr.

4.2.1 Instalace JOSM

Editor JOSM je volně dostupný open-source software, který je možné stáhnout z oficiálních stránek projektu na adrese <https://josm.openstreetmap.de/>. Díky implementaci v programovacím jazyce Java je multiplatformní a je kompatibilní s operačními systémy Windows, Linux i macOS. Pro správné fungování aplikace je nutné mít na počítači nainstalované prostředí Java Runtime Environment (JRE), přičemž při prvním spuštění JOSM automaticky detekuje jeho přítomnost.


Po stažení instalačního souboru a spuštění editoru si uživatel může zvolit jazykové rozhraní (včetně češtiny) a upravit základní nastavení podle preferencí. Editor při prvním spuštění nabízí výběr vzhledu, stylu zobrazení a formátování dat. Doporučuje se také nastavit automatické aktualizace, aby uživatel vždy pracoval s nejnovější verzí nástroje.

4.2.2 Instalace pluginů

Instalace pluginů v editoru JOSM je navržena s důrazem na uživatelskou přívětivost a jednoduché rozšíření funkčnosti editoru podle potřeb konkrétního uživatele. Pluginy lze instalovat přímo z prostředí editoru prostřednictvím nabídky „Předvolby“, kde se nachází záložka „Doplňky“. Do této nabídky se lze také dostat buď přes horní lištu editoru pod záložkou „Upravit“ → „Nastavení“, nebo pomocí klávesové zkratky F12.

Pro správnou funkčnost některých webových propojených služeb (např. Tasking Manager) je nezbytné aktivovat funkci „Vzdálené ovládání“ (Remote Control). Tato možnost se rovněž nachází v předvolbách a umožňuje externím aplikacím, aby otevřely přímo v JOSM konkrétní mapovací úkol.

V záložce „Doplňky“ je možné pomocí vyhledávacího pole najít požadovaný plugin, zaškrtnout příslušné pole a následně kliknout na tlačítko „Stáhnout seznam“. Po potvrzení tlačítkem „OK“ proběhne instalace a editor vyzve k restartu, pokud je to pro aktivaci vybraných rozšíření nutné.



Obrázek 6 Předvolby v programu JOSM

(zdroj: JOSM, 2025)

Nejčastěji doporučovaným pluginem v rámci humanitárního mapování je Buildings Tools, označovaný v seznamu jako „building_tools“. Pokročilejší uživatelé využívají rovněž další specializované pluginy, jako například Building Generalization nebo Mapathoner, které umožňují pokročilé operace s mapovými daty a podporují specifické pracovní postupy.

V případě, že instalace pluginu prostřednictvím grafického rozhraní není možná, lze využít alternativní postup. Plugin ve formátu .jar lze stáhnout z oficiálních stránek editoru a uložit do adresáře plugins v instalační složce JOSM na lokálním zařízení. Po opětovném

spuštění editoru budou tyto soubory automaticky načteny a zpřístupněny v uživatelském prostředí.

4.2.3 Načítání území

Samotná práce v editoru JOSM probíhá formou nahrání datové oblasti, kterou chce uživatel upravit. To lze provést prostřednictvím API rozhraní OpenStreetMap nebo importem externích dat (např. GPX, GeoJSON). Pro humanitární mapování je obvyklé využití podkladových snímků, například od poskytovatele Bing nebo Maxar, které jsou dostupné přímo v editoru.

V rámci experimentu byly účastníkům zaslány dva odkazy, které sloužily k načtení mapovací oblasti do prostředí JOSM. První z těchto odkazů otevřel prázdné území, zatímco druhý umožnil načtení konkrétního snímku určeného pro mapování. Tento postup umožnil jednotné přidělení úloh a kontrolované prostředí pro sledování výkonnosti jednotlivých účastníků.

Pro zahájení editace bylo nutné v editoru vytvořit novou mapovou vrstvu. Tato operace se provádí prostřednictvím nabídky „Soubor“ → „Nová vrstva“, čímž se otevře editační prostor, do kterého mohou být vkládány nové objekty. Mapování probíhá právě v této aktivní vrstvě.

4.2.4 Mapování v JOSM

Uživatel vybírá objekty, které chce editovat (např. budovy, komunikace, vodní prvky), a následně je ručně vektorizuje s využitím základních nebo rozšířených nástrojů. Kreslení polygonálních objektů lze výrazně urychlit pomocí pluginu Buildings Tools, který umožňuje tvorbu pravoúhlých struktur jediným kliknutím. Mapování je doplněno o přidání atributových údajů, například typu budovy, počtu podlaží či povrchu komunikace. JOSM umožňuje při mapování využívat vrstvy, filtry, vlastní styly a kontrolní nástroje. Pomocí validátoru lze průběžně odhalit a opravit chyby. Před finálním nahráním změn na server OSM je možné celý projekt uložit lokálně, případně exportovat do formátu vhodného pro další zpracování (např. *.osm nebo *.geojson).

Mapování v prostředí JOSM probíhá buď prostřednictvím pluginu Buildings Tools, nebo ručně. Při kreslení pravoúhlých a kruhových budov se doporučuje využít zmíněný plugin, který lze aktivovat pomocí klávesy B. Přepínání mezi tvarem budovy (pravoúhlá

nebo kruhová) se provádí pomocí zkratk Alt+Z / Alt+R (MacOS: Option+Z / Option+R). Kreslení pravoúhlé budovy probíhá třemi kliknutími; po dvou stranách editor doplní zbývající hrany automaticky. U kruhových budov se kliká pouze na obvod a tvar je dopočítán.

Vytvořený prvek je automaticky označen jako budova. Stav objektu je možné ověřit v sekci „Značky/Členství“ po jeho výběru klávesovou zkratkou S. Pro smazání nežádoucích prvků se využívá klávesa Delete (MacOS: Fn+Backspace).

Pro složitější tvary je třeba kreslit ručně. Proces se zahajuje stiskem klávesy A, následným klikáním na zlomové body obvodu objektu a zakončením dvojklikem na počáteční bod. Výsledné polygonální objekty lze následně upravit: pravoúhlý tvar pomocí klávesy Q, kruhový tvar pomocí zkratky Shift+O (MacOS: Option+O). Každý objekt je třeba opatřit příslušnou značkou, například kombinací klávesy S pro výběr a kliknutím na „Přidat“ v sekci „Značky/Členství“, kde se ručně doplní atribut building=yes.

Přehled klávesových zkratk pro kreslení:

Buildings Tools:

- B – začít kreslit
- Alt+R / Alt+Z (Option+R / Option+Z) – přepínání tvaru
- S – výběr objektu
- Delete / Fn+Backspace – smazání objektu
- Ruční kreslení:
- A – začít kreslit
- Dvojklik – ukončení polygonu
- Q – pravoúhlý tvar
- Shift+O / Option+O – kruhový tvar
- S – výběr objektu
- Přidat → building / yes – doplnění značky

Orientace v mapovém prostředí je intuitivní. Uživatel se může po mapě pohybovat podržením pravého tlačítka myši a pohybem v požadovaném směru. Změna měřítka se

provádí pomocí kolečka myši. Levé tlačítko slouží k výběru a kreslení prvků, například polygonů, linií nebo bodových objektů.

4.2.5 Ukládání dat

Data vytvořená v rámci experimentu nebyla nahrávána do globální databáze OpenStreetMap, ale byla ukládána lokálně. Účastníci po dokončení úlohy klikli pravým tlačítkem na mapovou vrstvu, ve které probíhalo mapování, a zvolili možnost „Uložit jako“. Soubor byl uložen ve formátu. gejson, přičemž název odpovídal uživatelskému jménu v systému OSM.

Doporučeno bylo ukládání na plochu počítače pro snadnou dohledatelnost. Po uložení souboru byl editor ukončen volbou „Ukončit okamžitě!“ v potvrzovacím dialogovém okně. Výsledné soubory byly následně odevzdány pro účely vyhodnocení experimentu.

5 METODIKA

V rámci diplomové práce proběhl experiment, který se konal v říjnu 2024. Jeho náplní bylo porovnání efektivity a účinnosti mapování s umělou inteligencí v rámci projektu fAIr, která využívá asistenci umělé inteligence pro predikci obrysů budov a tradičním manuálním editorem JOSM, který využívá komunita OpenStreetMap. Experiment byl zaměřen na ověření přínosů nástrojů využívajících umělou inteligenci v prostředí dobrovolnického a humanitárního mapování.

Součástí přípravy experimentu bylo také vypracování testovacího plánu, jenž specifikoval testované prvky, aplikované metody, sledované metriky a způsoby jejich měření.

Použitá metodika byla konzultována se zástupci organizace Humanitarian OpenStreetMap a s odborníkem Omranem Najjarem, který stojí za vývojem fAIr projektu.

5.1 Cíle a hypotézy

Cílem testování bylo ověřit, do jaké míry použití dat předem vygenerovaných umělou inteligencí usnadňuje humanitární mapování a zda existuje korelace mezi zkušenostmi s mapováním budov a kvalitou (efektivitou) a kvantitou (účinností) během experimentu

Na základě těchto cílů byly stanoveny dvě hypotézy:

- H1: Mapování pomocí nástroje fAIr je rychlejší než ruční digitalizace v editoru JOSM
- H2: Mapování pomocí nástroje fAIr je více přesné než v JOSM.

5.2 Testovací prostředí

Experiment byl realizován v online prostředí, a to v předem domluvených časových blocích v termínech mezi 7. a 11. říjnem 2024, aby byl zajištěn dostatek flexibility pro všechny účastníky, komunikace probíhala prostřednictvím platformy Microsoft Teams. Jednotlivé části experimentu byly doplněny o instruktážní webináře, distribuované materiály a řízenou asistenci při technických obtížích. Účastníci pracovali na vlastních noteboocích s připojením externí myši a připojením k internetu. Při testování nebyly použity audio či video záznamy ani žádné speciální nástroje pro hodnocení použitelnosti.

5.3 Forma testování

Vzhledem k tomu, že se nepodařilo oslovit větší počet zájemců, bylo testování realizováno formou within-subject designu. Tento přístup znamená, že každý účastník plní všechny části experimentu, tedy v našem případě pracuje s oběma testovanými editory. Hlavní výhodou této metody je nižší potřeba účastníků, protože každý z nich slouží zároveň jako vlastní srovnávací jednotka.

Dalším benefitem tohoto přístupu je částečné potlačení vlivu vnějších proměnných, které není možné přímo kontrolovat. Například pokud má účastník v průběhu testování zhoršenou náladu nebo únavu, tento stav ovlivní výsledky v obou testovacích blocích, nikoliv jen v jednom, čímž se snižuje riziko systematického zkreslení výsledků (SECRET STACHE, 2023).

Na druhou stranu však tento typ testování přináší i určitá úskalí. Jedním z nejčastěji zmiňovaných je efekt učení, tzn. že účastníci se mohou během prvního bloku naučit pracovat efektivněji a ve druhé části pak dosahují lepších výsledků (SECRET STACHE, 2023). V tomto konkrétním experimentu ale tento faktor nehrál zásadní roli, jelikož většina účastníků již měla předchozí zkušenosti s humanitárním mapováním a prací v editorech, takže výkonnost nebyla výrazně ovlivněna postupným učením.

V případě, že by se podařilo zapojit větší počet účastníků, bylo by vhodné uvažovat o between-subject přístupu, kde by jednotlivé skupiny pracovaly s rozdílnými editory. Tento přístup sice vyžaduje více lidí, ale zároveň eliminuje efekt učení, protože každý účastník pracuje jen s jedním nástrojem.

5.4 Účastníci

Prvním krokem v přípravě experimentu bylo považováno zajištění dostatečného počtu účastníků. S ohledem na tuto potřebu byli potenciální zájemci osloveni již na začátku podzimního semestru roku 2024.

Do propagace se aktivně zapojila komunita humanitárního mapování, která informace o experimentu sdílela prostřednictvím svých facebookových kanálů. Paralelně byli osloveni také studenti geografického ústavu na Masarykově univerzitě. Tímto způsobem se podařilo oslovit jak zkušené přispěvatele z praxe, tak akademické nováčky, čímž byla zajištěna různorodost účastnické skupiny.

Zájemci o účast v experimentu vyplnili registrační formulář vytvořený pomocí Google Forms, který obsahoval stručné představení projektu a jeho cílů. V rámci formuláře účastníci uvedli svůj e-mailový kontakt a uživatelské jméno v OpenStreetMap, a zároveň potvrdili souhlas se zpracováním osobních údajů v souladu s GDPR.

Vysvětlení k účelu experimentu jasně zdůrazňovalo, že hlavním cílem je přispět k rozvoji nástrojů umělé inteligence pro humanitární mapování, konkrétně testování platformy fAIr mapping (<https://fair.hotosm.org/>), vyvíjené organizací Humanitarian OpenStreetMap Team. Zároveň bylo uvedeno, že výsledky budou využity jako podklad pro závěrečné práce studentů Geografického ústavu Přírodovědecké fakulty Masarykovy univerzity.

Zájemci byli informováni, že experiment proběhne převážně online, a to v českém i anglickém jazyce, aby se do něj mohli zapojit i účastníci ze zahraničí. Bylo rovněž zdůrazněno, že účast nevyžaduje žádnou fyzickou přítomnost v Brně ani cestovní výdaje.

Podmínkou účasti byla:

- základní znalost práce v editoru JOSM, odpovídající úrovni pravidelného humanitárního mapéra,
- vlastní uživatelský účet v OpenStreetMap,
- a vyplnění souhlasu se zpracováním údajů prostřednictvím formuláře dostupného na adrese: <https://forms.gle/c2djnENa5TRranA67>

Zájemcům, kteří s editorem JOSM neměli předchozí zkušenosti, byla nabídnuta možnost účasti na online školení, která probíhala v týdnech před začátkem experimentu.

Uvedené uživatelské jméno v OSM bylo následně využito k přiřazení konkrétních mapovacích lokalit každému účastníkovi.

5.4.1 Participanti

Dle různých odborníků jsou doporučeny různé přístupy k počtu účastníků zapojených do testování. Vzhledem k tomu, že testování bylo zaměřeno na dobrovolnickou činnost a oba nástroje jsou volně dostupné, nebylo nutné striktně vymezit cílovou skupinu. Proto byli jako participanti zvoleni v přiměřeném počtu začátečníci a zkušení přispěvatelé z humanitárních mapovacích komunit. Celkem se experimentu zapojilo 26 účastníků (viz. Tabulka 1)

Tabulka 1 Profil participantů

(zdroj: vlastní tvorba, 2024)

Kategorie	Počet	Zkušenosti
Začátečníci	14	Základní
Zkušení	12	Pokročilé

5.5 Vymezení lokalit

Mapování v rámci experimentu probíhalo na různých územích z celého světa, aby bylo zajištěno diverzifikace území s odlišnými podmínkami urbanizace, geografickými charakteristikami a hustotou zástavby. Tyto lokality byly zvoleny tak, aby umožnily validní srovnání výkonnosti mapovacích nástrojů ve variabilních kontextech, od hustě zastavěných městských oblastí až po rozptýlenou venkovskou zástavbu.

Chyba! Nenalezen zdroj odkazů. zachycuje jednoduchou mapovací oblast v Kamerunu, která je charakteristická pravidelnou zástavbou a dobrým kontrastem mezi budovami a okolím, na rozdíl **Chyba! Nenalezen zdroj odkazů.** znázorňuje komplexní mapovací prostředí v Monrovii, kde jsou podmínky komplikovány hustou zástavbou a obtížně rozeznatelnými přechody mezi objekty. Tyto jsou způsobeny především nízkým kontrastem snímku, který je ovlivněn přítomností barevně různorodých střech, často sestavených z kombinace různých materiálů a odstínů.



Obrázek 8 Ukázka jednoduché lokality
Kamerun

(zdroj: fAIr, 2024)



Obrázek 8 Ukázka komplexní lokality
Monrovia

(zdroj: fAIr, 2024)

Celkem bylo připraveno 24 mapovacích úloh, přičemž každá lokalita byla předem zpracována jako trénovací datová sada v prostředí platformy fAIr. Výběr oblastí zahrnoval území z různých kontinentů a rozvojových regionů, což odpovídá charakteru humanitárního mapování, jež se typicky zaměřuje právě na tyto části světa.

Cílem bylo ověřit schopnost modelu umělé inteligence adaptovat se na různorodé prostorové podmínky a zároveň umožnit porovnání výsledků s manuálním mapováním v editoru JOSM. Každému účastníkovi byla v rámci jednoho testovacího nástroje přidělena jedna lokalita ve formě TMS³ odkazu, který sloužil k načtení příslušného území v daném editoru. Výsledky mapování byly ukládány ve formátu GeoJSON pro účely následné analýzy.

Mapování probíhalo na základě aktuálních satelitních snímků z platformy OpenAerialMap (OAM), a to v měřítku odpovídajícím úrovní přiblížení zoom 19–21. Tato úroveň detailu byla nezbytná pro správnou identifikaci objektů v terénu.

5.6 Scénáře

Scénář experimentálního testování byl navržen tak, aby umožnil systematické sledování výkonnosti účastníků při mapování v rozdílných geografických, urbanistických a technických podmínkách. Každému účastníkovi byla přidělena jedna mapovací úloha, jak

³ Vysvětlivka TMS tile Map service (protokol pro zobrazování rastrových map rozdělených do dlaždic)

ve fAIr, tak v editoru JOSM, přičemž bylo zajištěno, aby každá lokalita byla reprezentována jak začátečníkem, tak pokročilým mapérem.

Účastníci obdrželi jasné instrukce ke spuštění testovací relace prostřednictvím odkazu (TMS) a jejich úkolem bylo během stanoveného časového limitu (45 minut) zmapovat co nejvíce relevantních budov na základě podkladových snímků. Participantů byli rozděleni do skupin a každý pracoval s přiděleným modelem, po uplynutí 45 minut byly skupiny prohozeny.

V rámci testování byly řešeny dvě modelové úlohy. Ve fAIr probíhalo mapování formou validace před-generovaných návrhů budov, zatímco v JOSM se jednalo o plně manuální digitalizaci.

Součástí scénáře bylo rovněž zaznamenávání následujících metrik:

- Počet všech zmapovaných objektů
- Počet správně zmapovaných objektů (ověřeno kontrolorem)
- Doba trvání mapování (nastavena jednotně)

Cílem tohoto scénáře bylo vytvořit reálné podmínky odpovídající běžné dobrovolnické mapovací aktivitě v prostředí OpenStreetMap, přičemž byl kladen důraz na zachování srovnatelných vstupních podmínek napříč všemi účastníky. Tato struktura umožnila objektivní vyhodnocení rozdílů mezi nástroji, lokalitami i jednotlivými skupinami uživatelů.

5.7 Hodnocení dle ISO-Normy

Norma EN ISO 9241-11:2018 se zaměřuje na koncept použitelnosti v kontextu interakce mezi člověkem a systémem. V této práci se opíráme o část 11 této normy, která specifikuje, jaké informace je třeba zohlednit při hodnocení použitelnosti, zejména při měření výkonu a spokojenosti uživatele. Tato norma se nevztahuje pouze na použitelnost softwaru, ale také na interakci člověka s různými produkty nebo službami. Definice podle normy ISO 9241-11; software je považován za použitelný, pokud umožňuje uživateli efektivně, účinně a s uspokojením plnit své úkoly v daném kontextu použití (ABRAN et al. 2003).

Část 11 normy ISO 9241 se zaměřuje na tři klíčové aspekty hodnocení uživatelského prostředí: účinnost, efektivitu a spokojenost. Tyto atributy lze popsat následujícím způsobem (ČSN EN ISO 9241-11 2018).

Část 11 ISO normy 9241 definuje tři základní atributy, které zakládají na hodnocení uživatelského prostředí: účinnost, efektivitu a spokojenost, které dle normy ČSN EN ISO 9241-11 2018 lze následně charakterizovat.

- a) Účinnost (Efficiency): Míra přesnosti a úplnosti, s jakou uživatel úspěšně vykoná daný úkol. (ČSN EN ISO 9241-11, 2018)
- b) Efektivita (Effectiveness): Množství vynaložených zdrojů, jako je čas nebo úsilí, potřebné k dosažení požadovaného cíle. (ČSN EN ISO 9241-11, 2018)
- c) Spokojenost (Satisfaction): Celkový dojem uživatele z práce se systémem, zahrnující fyzické, mentální i emoční aspekty a jejich soulad s jeho očekáváními. (ČSN EN ISO 9241-11, 2018)

Při testování lze tyto pojmy lépe přiblížit a konkretizovat. Efektivita se zaměřuje na to, zda uživatel úspěšně splnil zadaný úkol. Účinnost hodnotí, kolik času, energie nebo jiných prostředků k tomu musel vynaložit a spokojenost pak vyjadřuje jeho subjektivní pohled na práci se systémem, tedy do jaké míry byl s jeho fungováním a ovládáním spokojen.

5.8 Statistické vyhodnocení výsledků

K vyhodnocení výsledných dat bylo využito několik statistických testů, jejichž cílem bylo analyzovat rozložení sesbíraných hodnot, zjistit vzájemné korelace mezi proměnnými a zkušeností účastníků, a také ověřit, zda se začínající a pokročilí uživatelé jednotlivých editorů liší statisticky významným způsobem.

Předzpracování dat probíhalo v Microsoft Excel, kde byly provedeny také první výpočty. Pro kontrolu správnosti výsledků byly statistiky znovu spočítány v Pythonu a finální analýza proběhla v IBM SPSS Statistics. Pro zpracování dat byly použity následující statistické testy, přičemž všechny byly vyhodnoceny na hladině významnosti 0,05.

Jako první byla ověřena distribuce dat pomocí Shapiro–Wilkova testu, který je standardně používán pro posouzení, zda datový soubor vykazuje normální rozdělení. Tento test byl aplikován samostatně pro každou kombinaci nástroje a metriky (tj. zvláště pro efektivitu a účinnost v prostředí fAIr a JOSM). Výsledky testu určily, zda bude v dalším kroku použit parametrický nebo neparametrický postup.

V případech, kdy alespoň jeden z porovnávaných výběrů nevykazoval normální rozdělení, byl použit Mann–Whitneyho U test. Tento neparametrický test slouží k porovnání

dvou nezávislých souborů a je vhodnou alternativou k t-testu tam, kde nejsou splněny předpoklady normality.

Pro porovnání dvou skupin s normalitou rozložení byla aplikována parametrická metoda, konkrétně t-test pro nezávislé výběry. Podrobné výsledky analýzy jsou dále uvedeny v kapitole **Chyba! Nenalezen zdroj odkazů..**

5.9 Průběh experimentu

Mapování proběhlo v online prostředí během října 2024 prostřednictvím platformy Microsoft Teams. Testování bylo navrženo tak, aby umožnilo účastníkům pracovat na vlastních zařízeních a poskytlo jim flexibilitu při volbě vhodného termínu. V rámci experimentu bylo v nástroji fAIr mapping vytvořeno a natrénováno 24 AI modelů, přičemž jejich vývoj probíhal ve spolupráci s Humanitarian OpenStreetMap Team, který je autorem tohoto nástroje. Účastníci experimentu následně poskytli zpětnou vazbu prostřednictvím online dotazníku.

Hlavním cílem bylo zapojit jak zkušené přispěvatele do OpenStreetMap (OSM), tak úplné začátečníky, aby bylo možné porovnat jejich přístup a zkušenosti při práci s AI. Propagace probíhala skrze sociální sítě a prostřednictvím kontaktních sítí OpenStreetMap Team a organizace Lékaři bez hranic. Celkově se do experimentu zapojilo 26 účastníků, z toho 14 začátečníků a 12 zkušených mapérů. Skupinu pokročilých tvořili zejména členové humanitárních mapovacích komunit z Česka a Slovenska, zatímco mezi začátečníky převažovali studenti Masarykovy univerzity. Kromě nich se účastnili i jednotlivci z dalších zemí.

Při návrhu experimentu byla zohledněna zkušenost z podobných studií organizovaných Humanitarian OpenStreetMap Team ve spolupráci s Nizozemským červeným křížem v roce 2021, stejně jako experimenty realizované na Masarykově univerzitě (Klimeš, 2023; Tomšů, 2023). Tyto studie se zaměřovaly na porovnání efektivity mapování v editorech iD a RapiD, přičemž druhý z nich integruje výsledky umělé inteligence.

Pro zajištění plynulého průběhu experimentu bylo předem uspořádány čtyři webináře, na kterých byli účastníci seznámeni s prací v nástroji fAIr mapping a editorem JOSM. Každý účastník obdržel stručný návod, aby se mohl na mapování připravit. Samotný experiment probíhal v rozmezí 7.–11. října 2024, což umožnilo účastníkům vybrat si nejvhodnější termín a čas podle svých možností a časových pásem.

Každý termín experimentu probíhal podle předem stanoveného scénáře, který byl přizpůsoben tak, aby zohlednil účast jak českých, tak zahraničních dobrovolníků. Celý experiment se uskutečnil v online prostředí.

Na začátku byli účastníci rozděleni do dvou skupin (A a B), přičemž bylo dbáno na rovnoměrné zastoupení zkušených mapérů a začátečníků v každé skupině. Každé skupině byla přidělena specifická lokalita pro mapování v nástroji fAIr mapping i v editoru JOSM.

- Experiment byl zahájen 10minutovým úvodem, v němž byly představeny cíle, struktura testování, postupy a kritéria hodnocení. Zároveň byli účastníci požádáni o vyplnění formuláře souhlasu s účastí na experimentu a se zpracováním údajů.
- Následoval 45minutový blok mapování, kde skupina A pracovala v prostředí fAIr mapping a skupina B v editoru JOSM. Po skončení prvního bloku byla zařazena 5minutová přestávka.
- V dalším 45minutovém bloku si skupiny prohodily nástroje – skupina A pokračovala v JOSM, zatímco skupina B mapovala ve fAIr.
- Na závěr proběhlo shrnutí, ukončení mapování a vyplnění online dotazníku, který sbíral zpětnou vazbu na práci s oběma editory, na využití umělé inteligence ve fAIr a na celkový průběh testování.

5.9.1 Průběh mapování

Všechna termíny experimentu probíhala dle jednotného scénáře a byla rozdělena do tří chronologických fází: úvodní, experimentální (mapovací) a závěrečné.

- Úvodní fáze sloužila primárně k organizačním a administrativním úkonům. V jejím rámci byla ověřena účast jednotlivců, zkontrolováno vyplnění registračního formuláře a souhlasu se zpracováním osobních údajů.
- Experimentální fáze zahrnovala vlastní mapovací činnost účastníků, realizovanou ve dvou editorech – fAIr mapping, využívajícím prvky umělé inteligence, a JOSM, představujícím tradiční nástroj pro ruční editaci dat v systému OpenStreetMap.
- Závěrečná fáze byla věnována shrnutí průběhu, reflexi ze strany účastníků a sběru zpětné vazby prostřednictvím standardizovaného online dotazníku.

5.9.1.1 Úvod experimentu

Na začátku zasedání byli účastníci obeznámeni s celkovým průběhem testování a časovým harmonogramem. Byly jim vysvětleny metriky, které budou sledovány – konkrétně kvantitativní metriky zahrnující rychlost a kvalitativní metriky zahrnující přesnost mapování. Důraz byl kladen na to, že hodnocení bude zohledňovat jak efektivitu práce, tak kvalitu výsledných dat.

Účastníkům byl před zahájením experimentu poskytnut čas na seznámení se s návody pro oba nástroje, přičemž manuály obsahovaly detailní postupy a příklady využití.

V případě nástroje fAIr byli účastníci instruováni prostřednictvím podrobného manuálu, který zahrnoval podstatné aspekty práce s umělou inteligencí pro mapování budov. Pokyny se zaměřovaly na správné nastavení parametrů, jako jsou Tolerance, Plocha a Pravděpodobnost, což umožňuje optimalizovat výsledky predikce na základě specifických potřeb mapované oblasti. Postup zahrnoval spuštění predikcí pomocí funkce „Run Prediction“, kontrolu přesnosti výsledných tvarů budov a možnosti jejich úpravy či schválení (fair tutorial).

Pro editor JOSM byl manuál zaměřen na ruční mapování budov a efektivní využití doplňků, například Buildings Tools, které zjednodušují kreslení pravoúhlých a kruhových budov. Účastníci byli seznámeni s instalací doplňků, jejich aktivací a aplikací v praktických scénářích mapování. Dále byly zahrnuty postupy pro kreslení složitějších tvarů budov a přidávání odpovídajících atributů, čímž byla zajištěna správná klasifikace objektů. Manuál byl zpracován s důrazem na jasnou strukturu a obsahoval ukázky kroků (josm tutorial).

Po úvodním seznámení byla účastníkům přidělena konkrétní modelová úloha, kterou měli splnit pomocí daného nástroje. Po dokončení úkolu byli účastníci vyzváni k vyplnění zpětné vazby pomocí formuláře, kde hodnotili jak svou zkušenost s nástrojem.

5.9.1.2 Mapování

Hlavní experimentální část se skládala ze dvou samostatných mapovacích bloků, z nichž každý trval 45 minut. Oba bloky byly odděleny krátkou 5minutovou přestávkou.

Před zahájením mapování byla provedena teoreticko-praktická instruktáž, která zahrnovala:

- představení mapovací lokality,

- technické nastavení příslušného editoru,
- upozornění na typické chyby, kterých je třeba se vyvarovat (např. překryv budov, chybné přichycení polygonu k podkladu, neuzavřená geometrie apod.).

Hlavním úkolem účastníků bylo v časovém rámci kvalitně zmapovat co nejvíce objektů. V průběhu každého bloku byli účastníci pravidelně informováni o zbývajícím čase, aby měli možnost včasné a bezpečné uložení svých editací.

Po dokončení prvního bloku došlo k prohození editorů mezi skupinami, čímž bylo zajištěno, že každý účastník pracoval v obou prostředích za co nejvíce srovnatelných podmínek.

5.9.1.3 Ukončení testování

Po ukončení mapovací části bylo všem účastníkům poděkováno za spolupráci a byl jim odeslán elektronický dotazník.

Dotazníky měly za cíl získat subjektivní zpětnou vazbu na jednotlivé aspekty editorů – jejich použitelnost, přehlednost, podporu uživatele při editaci, vnímanou efektivitu a celkový dojem z mapování. Tato data následně sloužila jako jeden z podkladů pro kvalitativní analýzu výsledků experimentu.

5.9.2 Dotazníkové šetření

Pro zajištění komplexní zpětné vazby a evaluaci efektivity nástroje fAIr mapping bylo po ukončení experimentu provedeno dotazníkové šetření. Účastníci vyplnili strukturovaný online dotazník, který byl navržen tak, aby reflektoval jak kvantitativní, tak kvalitativní aspekty uživatelské zkušenosti.

Dotazník obsahoval uzavřené i otevřené otázky, přičemž uzavřené položky byly postaveny na Likertově škále a hodnotily faktory, jako byla srozumitelnost instrukcí, přehlednost rozhraní, jednoduchost tvorby budov, správnost generovaných objektů a celková spokojenost s mapovacím procesem. Dále bylo zjišťováno, do jaké míry AI přispěla ke zrychlení a zkvalitnění mapování, zda účastníci považovali fAIr za vhodný nástroj pro začátečníky či pokročilé uživatele, a také jejich ochota používat tento editor v budoucnosti viz výsledky v kapitole [6.7.]

5.9.3 Export a validace dat

Samotný export byl proveden pro přesně definované časové období, odpovídající trvání mapovacího experimentu, a zahrnoval všechna OSM uživatelská jména účastníků, kteří se zapojili do testování. Data byla exportována ve standardizovaném formátu GeoJSON, který umožňuje efektivní analýzu prostorových dat a jejich následnou validaci.

Validaci exportovaných dat provedli Mgr. Radim Štampach, Ph.D. a Mgr. Milan Fila, kteří se přímo neúčastnili samotného mapování, avšak jsou zkušenými členy humanitární mapovací komunity s dlouhodobou praxí v oblasti verifikace prostorových dat. Validace se zaměřila na hodnocení kvality mapovaných objektů, přičemž hlavními parametry byla přesnost geometrie, dodržení topologických pravidel a identifikace chyb v datech.

Na základě validace bylo možné kvantifikovat počet a kvalitu zmapovaných budov jednotlivými účastníky a identifikovat četnost a typy chyb v generovaných datech. Výsledky této analýzy, jsou uvedeny v kapitole [6.1 a 6.2]

5.9.4 Vyhodnocení mapovaných dat

Po ukončení experimentu byla všechna mapovaná data vytvořená v prostředí fAIr a editoru JOSM podrobena validaci, kterou provedli nezávislí validátoři, zkušení přispěvatelé do humanitárních map OpenStreetMap. Cílem této validace bylo kvantifikovat chybovost mapovaných budov a identifikovat rozdíly mezi editory z hlediska přesnosti a kvality výstupů.

Každý účastník v rámci experimentu zmapoval rozdílné množství budov, přičemž byla posouzena topologickou správnost, přesnost geometrie a dodržení kartografických standardů. Na základě těchto kritérií byl stanoven počet chybně mapovaných budov pro každého účastníka, což umožnilo objektivní srovnání výsledků mezi editory.

Po dokončení validace byla získaná data statisticky analyzována. Statistické metody byly využity k identifikaci významných rozdílů mezi mapováním ve fAIr a JOSM, a to z hlediska míry chybovosti, efektivity a přesnosti výsledných dat. Výsledky této analýzy poskytují podklad pro závěrečné hodnocení přínosu umělé inteligence v humanitárním mapování a jsou podrobně rozpracovány v následujících kapitole „Analýza a výsledky“ [6].

5.9.5 Kritéria vyhodnocování

Pro potřeby analýzy kvality mapovacích výstupů byla před zahájením experimentu stanovena jednotná kritéria pro rozlišení správně a nesprávně zmapovaných budov. Tato kritéria vycházela ze zavedených standardů a zkušeností z oblasti humanitárního mapování, a byla účastníkům podrobně vysvětlena v úvodní fázi experimentu.

Použitá metoda hodnocení byla převážně subjektivního charakteru, což je běžné u expertně vedené validace v prostředí OpenStreetMap, kde často neexistují referenční datové sady s ověřenou správností, které by umožnily objektivní srovnání. Přesto byla validace provedena konzistentně a v souladu s běžně používanými postupy v mapovací komunitě.

5.9.5.1 Kritéria pro správně mapované budovy ve fAIr:

Vzhledem k tomu, že nástroj fAIr se nachází ve fázi vývoje a jeho výstupy jsou zatím nedostatečně stabilní z hlediska geometrické přesnosti, byla kritéria pro hodnocení mírně upravena, aby zohlednila technologická omezení tohoto editoru.

Za správně zmapovanou budovu ve fAIr byla považována budova, která splňovala následující podmínky:

1. Lokalizace – budova je umístěna ve správné poloze vůči satelitnímu snímku.
2. Tvarová přesnost – obrys odpovídá základnímu geometrickému tvaru (čtverec, obdélník, kruh).
3. Segmentace – nesmí dojít ke sloučení více budov do jedné geometrie.
4. Fragmentace – jedna budova nesmí být rozdělena do několika oddělených částí.
5. Překrytí se snímkem – minimální překryv polygonu budovy s reálným objektem na snímku činí alespoň 75 %, přičemž ideální hodnota je nad 90 %.

Dále byla zohledněna i vizuální „akceptovatelnost“ obrysu – kostrbaté či lehce nepravidelné obrysy nebyly hodnoceny jako zásadní problém, pokud bylo možné je jednoduše upravit (např. zpravoúhlit).

5.9.5.2 Kritéria pro správně mapované budovy v JOSM:

Editor JOSM je považován za stabilní a profesionální nástroj pro detailní mapování, a proto byla kritéria pro hodnocení dat vytvořených v tomto prostředí striktnější. Hodnotitelé posuzovali následující aspekty:

1. Lokalizace – budova musí být umístěna přesně podle satelitního snímku.
2. Pravoúhlost – budovy musí být zpravidla pravoúhlé, pokud tomu odpovídá jejich skutečný tvar.
3. Segmentace a sloučení – nesmí dojít ke sloučení více budov do jedné geometrie, ani ke zbytečné fragmentaci jedné budovy.
4. Topologická čistota – dvě budovy se nesmí překrývat.
5. Atributace – každá budova musí být označena pomocí atributu building=yes.
6. Tvarová věrnost – obrys by měl být obdélníkový nebo kruhový, pokud to odpovídá reálnému vzhledu objektu.

6 ANALÝZA A VÝSLEDKY

V této kapitole jsou prezentovány výsledky experimentu, zaměřené na ručně validovaná data zkušenými validátory. Posuzovány jsou ukazatele, jako počet zmapovaných budov, správnost mapování a procentuální úspěšnost, tedy podíl správně zmapovaných budov k celkovému počtu.

Tyto ukazatele jsou členěny do sekcí „Hodnocení efektivity“ číslo kapitoly [6.1] a „Hodnocení účinnosti“ číslo kapitoly [6.2], přičemž každá část obsahuje vyhodnocení dat ze dvou editorů; fAIr a JOSM. Struktura kapitoly odpovídá postupům hodnocení dle normy ISO 9241-11:2018, která byla podrobně popsána v kapitole [5.7]

Zkoumány byly rovněž rozdíly mezi účastníky s různou úrovní zkušeností, a to jak mezi jednotlivými editory, tak v rámci obou nástrojů. Úroveň zkušenosti byla definována na základě počtu budov zmapovaných před zahájením experimentu, přičemž hranice byla stanovena na 100 budov. Tyto údaje byly získány prostřednictvím reportu. Rozdělení účastníků na začátečníky a pokročilé umožnilo podrobně analyzovat rozdíly mezi skupinami, což je podrobně rozpracováno v sekci „Srovnání podle úrovně zkušenosti“ v kapitole [6.3].

Další část kapitoly, „Analýza chyb mapování“ [6.6], shrnuje nejčastější chyby vznikající během mapování. Součástí této části jsou také konkrétní příklady, které umožňují lépe pochopit problematické situace.

Poslední sekce kapitoly, nazvaná „Hodnocení spokojenosti“ [6.7], se opírá o výsledky dotazníkového šetření zaměřeného na zpětnou vazbu účastníků po práci v editoru RapiD. Dotazníky byly distribuovány elektronicky přes ... v závěrečné fázi experimentu.

6.1 Hodnocení efektivity mapování

Efektivita byla hodnocena jako počet správně zmapovaných budov za časovou jednotku, která byla pevně stanovena na 45 minut pro mapování v jednotlivém nástroji. Tento kvantitativní ukazatel sloužil k porovnání výkonnosti nástrojů z hlediska jejich schopnosti generovat výstupní data ve stanoveném časovém rámci. Účastníci byli instruováni k mapování v přidělené oblasti s důrazem na co nejpřesnější, avšak zároveň plynulé zpracování.

Tabulka 2 porovnání efektivity mezi vybranými nástroji

(zdroj: vlastní tvorba, 2025)

Nástroj	Počet účastníků	Celkový počet zmapovaných budov	Počet správně zmapovaných budov	Efektivita (budov/min)
fAIr	25	2220	1808	2,06
JOSM	25	4763	4303	4,23

Z výsledků vyplývá, že uživatelé dosáhli při mapování v editoru JOSM více než dvojnásobného množství budov oproti prostředí fAIr.

6.2 Hodnocení účinnosti mapování

Účinnost byla definována jako podíl správně zmapovaných budov z celkového počtu objektů, které byly účastníky během experimentu zakresleny. Hodnocení správnosti bylo provedeno ručně dvěma nezávislými validátory se zkušeností v humanitárním mapování. Za správně zmapovaný objekt byl považován takový, jehož geometrie i lokalizace odpovídaly reálnému obrysu budovy dle satelitního snímku. Do nesprávných záznamů byly započteny chyby typu sloučení více budov do jednoho polygonu, přílišné odchylky od obrysu nebo označení jiných objektů (např. stromů či vozidel) jako budov.

Tabulka 3 porovnání účinnosti mezi vybranými nástroji

(zdroj: vlastní tvorba, 2025)

Nástroj	Celkový počet zmapovaných budov	Počet správně zmapovaných budov	Účinnost (%)
fAIr	2220	1808	74,96
JOSM	4763	4303	86,08

Z tabulky č. 3 lze vidět, že editor JOSM dosáhl vyšší míry přesnosti v porovnání s nástrojem fAIr. Zatímco účinnost mapování v prostředí JOSM přesáhla 86 %, u nástroje fAIr byla zaznamenána hodnota přibližně 75 %.

6.3 Srovnání podle úrovně zkušenosti

Důležitým faktorem při hodnocení efektivity a účinnosti mapování byla úroveň předchozí zkušenosti jednotlivých účastníků s humanitárním mapováním. Výzkumný vzorek byl rozdělen do dvou skupin: začátečníci ($n = 14$), kteří měli pouze minimální, nebo žádné zkušenosti s editací v OpenStreetMap, a pokročilí uživatelé ($n = 12$), kteří již měli za sebou řadu mapovacích aktivit a ovládali pokročilé nástroje editoru JOSM.

Z tabulky č.4 lze vidět, že zkušenost mapování v JOSM výrazně ovlivňuje jak rychlost, tak kvalitu výstupů. Zkušení přispěvatelé dosahovali průměrné účinnosti 93,45 % a efektivity 5,69 budov za minutu. Začátečníci byli rovněž úspěšní, s účinností 79,28 % a efektivitou 2,89 budov za minutu, což svědčí o potenciálu nástroje i pro méně zkušené uživatele.

Tabulka 4 Srovnání efektivity a účinnosti v JOSM podle úrovně zkušenosti uživatele

(zdroj: vlastní tvorba, 2025)

Úroveň přispívatelů	Počet účastníků	Celkový počet zmapovaných budov	Počet správně zmapovaných budov	Průměrná účinnost (%)	Efektivita (budov/min.)
Začátečníci	13	1692	1391	79,28	2,89
Pokročilí	12	3071	2912	93,45	5,69

V tabulce č.5 jsou uvedeny výsledky v prostředí nástroje fAIr, které přinesly méně očekávané zjištění. Přestože tento nástroj využívá asistenci umělé inteligence a nabízí intuitivní rozhraní, zkušení uživatelé dosáhli nižší účinnosti (75,38 %) i nižší efektivity (1,84 budov/min) než začátečníci (účinnost 80,41 %, efektivita 2,08 budov/min). Tento vývoj může souviset s rozdílným přístupem k validaci predikovaných budov: pokročilí uživatelé vykazovali vyšší míru kritičnosti při hodnocení návrhů, což vedlo k nižší rychlosti a nižšímu počtu potvrzených objektů. Naopak začátečníci často přistupovali k validaci s menší opatrností, což se mohlo projevit vyšším tempem, ale ne vždy vyšší přesností.

Tabulka 5 Srovnání efektivity a účinnosti v fAIr podle úrovně zkušenosti uživatele

(zdroj: vlastní tvorba, 2025)

Úroveň příspěvatelů	Počet účastníků	Celkový počet zmapovaných budov	Počet správně zmapovaných budov	Průměrná účinnost (%)	Efektivita (budov/min.)
Začátečníci	14	1310	1061	80,41	2,08
Pokročilí	11	910	747	75,38	1,84

6.4 Srovnání podle náročnosti oblasti

K experimentu byly připraveny tréninkové datové sady pro 24 různých lokalit z celého světa, přičemž výběr zahrnoval různorodost prostředí a podmínek pro mapování.

Zohledněny byly dvě základní kategorie lokalit;

- „jednoduché oblasti“, definované jako území s pravidelnou zástavbou, dobrou čitelností satelitních podkladů a menším výskytem překryvů objektů, zatímco
- „komplexní oblasti“ byly charakterizované vysokou hustotou budov, nepravidelnou geometrií zástavby, stínovými efekty, vegetačními překryvy nebo nižší kvalitou leteckých snímků.

Z celkového počtu bylo 14 lokalit zařazeno do kategorie „jednoduché“ a 10 do kategorie „komplexní“. Součástí analytické části výzkumu bylo rovněž hodnocení výkonnosti nástrojů fAIr a JOSM ve vztahu k náročnosti mapované oblasti, která ověřovala, do jaké míry je efektivita a účinnost mapování ovlivněna charakterem prostředí, a zda se odolnost nástrojů vůči složitosti mapovacích podmínek liší.

Data byla zpracována samostatně pro obě kategorie, a to zvlášť v rámci každého testovaného nástroje.

Tabulka 6 výsledky dle náročnosti oblasti v fAIr

(zdroj: vlastní tvorba, 2025)

Náročnost oblasti	Účinnost (%)	Efektivita (budov/min)
Náročná	62,49	1,94
Snadná	87,43	2,17

Výsledky testování ukázaly, že nástroj fAIr je v náročnějších podmínkách výrazně méně efektivní. Při mapování ve snadných oblastech dosahovali uživatelé v průměru účinnosti přes 87 %, zatímco v komplikovaných oblastech poklesla přesnost výstupu na 62,49 %, tedy o více než 24 %. Oproti tomu efektivita zůstala téměř nezměněna, s poklesem pouze o 0,23 budovy za minutu.

Tento rozdíl lze interpretovat jako důsledek omezené schopnosti aktuálního AI modelu přesně predikovat budovy v nepřehledném prostředí bez pokročilého post-processingu, který by geometricky upravil tvarové odchylky či odfiltroval chybné návrhy. Uživatel má možnost pouze potvrdit nebo ignorovat návrh vytvořený umělou inteligencí, a to bez zpětné editace geometrie či atributů. V důsledku toho může práce i v náročnější oblasti pokračovat v přibližně stejném tempu, avšak s nižší přesností výsledků, neboť predikovaný výstup není vždy v souladu s realitou.

Tabulka 7 výsledky dle náročnosti oblasti v JOSM

(zdroj: vlastní tvorba, 2025)

Náročnost oblasti	Účinnost (%)	Efektivita (budov/min.)
Náročná	83,03	3,47
Snadná	88,89	4,49

V případě editoru JOSM byla zjištěna výrazně vyšší stabilita účinnosti. Při mapování v náročném prostředí došlo pouze k mírnému poklesu přesnosti (o 5,86 %), což ukazuje na schopnost uživatelů korigovat komplikovanější obrysy a správně interpretovat vizuálně náročné snímky. Naproti tomu efektivita se snížila o více než jednu budovu (1,02 budovy/min), tedy přibližně o 22,7 %. Tento trend odpovídá vyšší časové náročnosti ručního mapování v komplikovaném terénu, které vyžaduje pečlivější práci s geometrií, kontrolu topologie a časově náročnější rozhodování.

6.5 Statistická analýza výsledků

Za účelem objektivního posouzení, zda rozdíly v účinnosti a efektivitě mezi nástroji fAIr a JOSM představují statisticky významné odlišnosti, byla provedena sada kvantitativních testů. Tato část ověřuje, zda lze pozorované rozdíly mezi výkonností nástrojů považovat za náhodné, nebo zda reflektují systematické charakteristiky způsobené rozdílnou povahou nástrojů.

6.5.1 Testování normality dat

Před výběrem vhodného testu pro porovnání výkonnostních metrik bylo nezbytné ověřit, zda sledované proměnné vykazují normální rozdělení. Pro tento účel byl aplikován Shapiro–Wilkův test, který patří mezi standardní metody detekce odchylek od normální distribuce. Test byl proveden samostatně pro každou kombinaci nástroje a hodnocené metriky (účinnost a efektivita).

Tabulka 8 rozdělení normality pro testované nástroje

(zdroj: vlastní tvorba, 2025)

Test	p-hodnota	Interpretace
Shapiro-Wilk pro fAIr (efektivita)	0,0000072747	Data nejsou normálně rozdělena
Shapiro-Wilk pro JOSM (efektivita)	0,0000000623	Data nejsou normálně rozdělena
Shapiro-Wilk pro fAIr (účinnost)	0,0002460060	Data nejsou normálně rozdělena
Shapiro-Wilk pro JOSM (účinnost)	0,0020851093	Data nejsou normálně rozdělena

6.5.2 Testování statistických rozdílů

Ve všech případech byla p-hodnota nižší než hladina statistické významnosti $\alpha < 0,05$. Na základě těchto výsledků bylo rozhodnuto o použití neparametrického Mann–Whitneyho U testu, který je vhodný pro nenormálně rozložená data.

Tabulka 9 statistické testování obou nástrojů

(zdroj: vlastní tvorba, 2025)

Test	p-hodnota	U-statistika	Interpretace
Mann-Whitney U Test pro účinnost	0,0085	168	statisticky významný rozdíl ($p < 0,05$)
Mann-Whitney U Test pro efektivitu	0,00087	133	statisticky vysoce významný rozdíl

Výsledky ukázaly, že rozdíly mezi nástroji jsou statisticky významné jak v oblasti efektivity (počet budov za minutu), tak účinnosti (přesnosti) mapování. Toto zjištění potvrzuje, že nástroj JOSM dosahuje statisticky vyšší efektivity i účinnosti než nástroj fAIr. Tyto výsledky umožňují spolehlivě zamítnout nulovou hypotézu o rovnosti výkonu obou nástrojů a potvrdit, že z hlediska měřitelných parametrů je rozdíl mezi nimi statisticky prokazatelný.

6.5.3 Statistické porovnání nástrojů podle úrovně zkušenosti

Nástroje byly porovnávány také podle úrovně zkušenosti uživatelů s cílem zjistit, zda mezi skupinou začátečníků a zkušených přispěvatelů existují statisticky významné rozdíly ve výkonnosti při mapování ve fAIr a JOSM. Výkonnost byla hodnocena z hlediska účinnosti (tj. přesnosti výstupu) a efektivity (tj. rychlosti mapování), přičemž analýza byla provedena zvlášť pro každou ze dvou skupin uživatelů i pro každý nástroj.

Před samotným testováním hypotéz byl nezbytné ověřit normalitu rozdělení dat pomocí Shapiro–Wilkova testu. V případech, kdy data nevykazovala normální rozdělení, byl použit neparametrický Mann–Whitneyho U test, jinak byl zvolen parametrický t-test pro nezávislé vzorky.

a) Účinnost – začátečníci fAIr vs. JOSM

Statistické porovnání účinnosti mapování mezi začátečníky používajícími nástroje fAIr a JOSM můžeme vidět v následující tabulce č. 10.

Tabulka 10 rozdělení normality účinnosti začátečníků podle Shapiro-Wilkova testu

(zdroj: vlastní tvorba, 2025)

Nástroj	Průměrná účinnost začátečníků (%)	p-hodnota	Statisticky významný rozdíl ($p < 0,05$)
fAIr	80,41	0,000844	Data nemají normální rozdělení
JOSM	79,28	0,000064	Data nemají normální rozdělení

Na základě výsledků Shapiro–Wilkova testu byla normalita rozdělení zamítnuta, a proto byl aplikován neparametrický Mann–Whitneyho U test. Výsledná p-hodnota Mann–Whitneyho U testu $p = 0,5726$ neprokázala statisticky významný rozdíl mezi oběma nástroji na hladině významnosti $< 0,05$.

Přestože účinnost začátečníků byla ve fAIr (80,41 %) mírně vyšší než v JOSM (79,28 %), rozdíl nebyl statisticky významný. Lze tedy konstatovat, že přesnost mapování u začátečníků nezávisí na zvoleném nástroji.

b) Účinnost – zkušební přispěvatelé fAIr vs. JOSM

V následující tabulce 11 lze vidět porovnání účinnosti mapování mezi zkušenými přispěvateli při použití nástrojů fAIr a JOSM.

Tabulka 11 rozdělení normality účinnosti zkušených účastníků podle Shapiro-Wilkova testu

(zdroj: vlastní tvorba, 2025)

Nástroj	Průměrná účinnost pokročilých (%)	p-hodnota	Statisticky významný rozdíl ($p < 0,05$)
fAIr	75,38	0,000218	Data nemají normální rozdělení
JOSM	93,45	0,057324	Data mají normální rozdělení

Vzhledem k tomu, že normalita na základě Shapiro–Wilkova testu rozdělení byla porušena u jedné skupiny, byl aplikován Mann–Whitneyho U test. Statistická analýza prokázala významný rozdíl mezi nástroji ($p = 0,001736 < 0,05$), což indikuje vyšší přesnost výstupu v prostředí JOSM.

Zkušební uživatelé dosáhli výrazně vyšší účinnosti v JOSM (93,45 %) než ve fAIr (75,38 %). Tento rozdíl je statisticky významný a potvrzuje vyšší kvalitu mapování zkušených editorů v prostředí, které umožňuje manuální editaci a kontrolu nad daty.

c) Efektivita – zkušební přispěvatelé fAIr vs. JOSM

Statistické porovnání efektivity mapování mezi zkušenými přispěvateli využívajícími nástroje fAIr a JOSM je k nahlédnutí v tabulce č.12.

Tabulka 12 rozdělení normality efektivity zkušených uživatelů podle Shapiro-Wilkova testu

(zdroj: vlastní tvorba, 2025)

Nástroj	Průměrná efektivita začátečníků (budov/min)	p-hodnota	Statisticky významný rozdíl ($p < 0,05$)
fAIr	1,84	0,212017	Data mají normální rozdělení
JOSM	5,69	0,227185	Data mají normální rozdělení

Vzhledem k tomu, že obě skupiny vykazovaly normální rozdělení hodnot, byl použit t-test pro nezávislé výběry. Výsledek testu ($p = 0,0031$) prokázal statisticky významný rozdíl ve prospěch nástroje JOSM.

Rychlost mapování byla u zkušených přispěvatelů v JOSM (5,69 budov/min) výrazně vyšší než ve fAIr (1,84 budov/min). Tento rozdíl je statisticky významný a ukazuje na efektivní využití nástrojů editoru JOSM zkušenými mapéry.

Začátečníci dosáhli překvapivě lepších výsledků v účinnosti a efektivitě ve fAIr než zkušení přispěvatelé. Tento rozdíl však není statisticky významný. Výkonnost začátečníků a zkušených účastníků ve fAIr je tedy podobná.

V JOSM je rozdíl mezi začátečníky a pokročilými uživateli výraznější, a to ve prospěch zkušených přispěvatelů. Začátečníci vykazují podobnou účinnost při použití fAIr i JOSM a jen mírně nižší efektivitu ve fAIr než v JOSM. Na druhé straně, zkušení přispěvatelé dosahují v JOSM lepších výsledků než začátečníci.

6.6 Analýza chyb mapování

Při kontrole dat zmapovaných ve fAIr byly identifikovány nejčastější chyby. Tabulka 13 ukazuje jejich rozložení pro jednoduché a komplexní lokality.

Tabulka 13 Počet účastníků, u kterých byl zjištěn daný typ chyby při mapování ve fAIr

(zdroj: vlastní tvorba, 2025)

Typy chyb v fAIr	Začátečník snadná oblast	Začátečník náročná oblast	Zkušený snadná oblast	Zkušený náročná oblast
Více budov zakresleno jako jeden obrys	4	6	4	3
Budovy nebo skupiny jsou posunuté	1	1	0	2
Obrys neodpovídá tvaru budovy	3	5	4	3
Méně než 90% plochy budovy je pokryto obrysem	1	2	4	2

Složitost mapované lokality (např. hustota budov v mapované oblasti a kvalita snímku) má významný dopad na začátečníky, kteří vykazují více chyb u složitějších úkolů. Zkušení uživatelé si udržují konzistentnější výsledky napříč různými úrovněmi obtížnosti, což ukazuje na jejich lepší schopnost adaptace.

Začátečníci dělají více chyb ve všech typech lokalit, což naznačuje potřebu dalšího školení nebo podpory, zejména při práci na složitějších úkolech. Zkušení uživatelé vykazují méně chyb a větší konzistenci, což zdůrazňuje jejich lepší schopnosti při mapování.

Chyby jako „Více budov zakresleno jako jeden obrys“ a „Obrys neodpovídá tvaru budovy“ patří mezi nejčastější problémy u obou skupin, bez ohledu na jejich zkušenosti. To naznačuje, že tyto aspekty by mohly být oblastmi pro zlepšení kvality mapování ve fAIr, např. prostřednictvím lepších nástrojů nebo instrukcí pro správnou identifikaci a oddělení jednotlivých budov. Vyšší počet těchto typů chyb je zjištěn ve složitějších lokalitách, kde AI pravděpodobně generovala obrysy budov nižší kvality.


Nejčastější typy chyb při mapování budov navržené AI ve fAIr (Tabulka 13) byly porovnány s nejčastějšími typy chyb při manuálním mapování v JOSM:

- Budovy nejsou pravoúhlé, přestože by měly být.
- Obrys nepokrývá celou budovu.
- Obrys neodpovídá tvaru budovy.
- Více budov je zmapováno jako jeden objekt.
- Jedna budova je rozdělena na více budov.
- Obrys budovy není uzavřený – netvoří polygon.
- Budova nemá atribut `building=yes`.

Data v JOSM byla kreslena manuálně účastníky, ale nejčastější chyby jsou podobné těm, které se objevují v datech vytvořených AI v nástroji fAIr. Některé typy chyb, které mohou vzniknout při manuálním mapování v JOSM, jako například neuzavřený obrys budovy nebo chybějící atribut však ve fAIr, kde budovy připravuje AI, nemohou nastat. To představuje jednu z výhod nástroje fAIr.

6.7 Hodnocení spokojenosti


Součástí evaluace byla rovněž kvalitativní analýza subjektivní zpětné vazby účastníků, získaná prostřednictvím online dotazníku. Účastníci (23) hodnotili oba nástroje z hlediska srozumitelnosti, přívětivosti uživatelského rozhraní, rychlosti orientace, míry potřebné asistence a celkové spokojenosti s pracovním prostředím.



Obrázek 9 otevřený dotazník

(zdroj: vlastní tvorba, 2025)


Otevřené otázky v dotazníkovém šetření poskytly hlubší vhled do subjektivních zkušeností účastníků s editory fAIr mapping a JOSM. Respondenti sdíleli své názory na uživatelskou přívětivost, efektivitu práce, přesnost generovaných dat a vhodnost nástrojů pro humanitární mapování. Získaná data ukázala významné rozdíly ve vnímání obou editorů v závislosti na zkušenostech jednotlivých účastníků a charakteru mapovaných oblastí.



Obrázek 10 uzavřený dotazník k chybějícím instrukcím

(zdroj: vlastní tvorba, 2025)


Jedním z hlavních problémů, na které účastníci upozornili, byly technické komplikace a neúplné instrukce. Někteří respondenti postrádali podrobnější vysvětlení během instruktáže, zejména v rámci „breakout room“ sekcí. Technické potíže se vyskytly zejména u editoru JOSM, kde někteří uživatelé naráželi na problémy se správnou verzí softwaru nebo nerozuměli některým pokročilým funkcím, jako jsou parametry Q a práce s vrstvami. U fAIr bylo zmiňováno, že chybí možnost zpětného zrušení potvrzené budovy, což vedlo k nemožnosti opravit chybná rozhodnutí.



Obrázek 11 uzavřený dotazník o využití fAIr při mapování

(zdroj: vlastní tvorba, 2025)

V porovnání editorů JOSM a fAIr se ukázaly zásadní rozdíly v jejich využití. JOSM byl vnímán jako nástroj umožňující preciznější kontrolu nad mapováním, což oceňovali zejména zkušenější uživatelé. Nabízel lepší možnosti manuální editace a umožňoval pracovat s komplexnějšími objekty. Naopak fAIr byl hodnocen jako nástroj, který výrazně urychluje proces mapování, avšak s omezenou možností editace a nižší kvalitou generovaných objektů. Automatická detekce budov fungovala efektivně pouze pro jednoduché obdélníkové objekty, zatímco složitější stavby často vyžadovaly manuální opravy.



Obrázek 12 uzavřený dotazník pro preferovaný nástroj

(zdroj: vlastní tvorba, 2025)

Někteří účastníci vyjádřili obavy ohledně kvality dat generovaných AI. Poukazovali na to, že pokud budou AI generované objekty schvalovány méně zkušenými uživateli, mohlo by to vést k poklesu kvality OpenStreetMap dat. Rovněž zaznělo, že fAIr neumí spolehlivě odlišit jednotlivé budovy, často slučuje objekty do nesmyslných celků nebo naopak některé stavby vůbec nerozpozná. Kromě toho bylo upozorněno na nutnost lepšího označení AI generovaných dat, aby bylo možné je jednoznačně odlišit od manuálních úprav.

Začátečníci vnímali fAIr jako vstřícnější prostředí s nižší vstupní bariérou. Oceňovali jednoduché rozhraní, možnost upravit výstup modelu a vizuální přehlednost. U editoru JOSM často poukazovali na počáteční nepřehlednost, nutnost zvládnutí vrstev a komplikovanější práci s geometrií.

Zkušení uživatelé hodnotili JOSM jako nástroj s vysokou mírou kontroly nad výstupem a preferovali jej pro jeho přesnost a robustnost. fAIr vnímali spíše jako doplňkový nebo předvýběrový nástroj, který však nenabízí dostatečnou flexibilitu při úpravě výsledků.

6.8 Shrnutí analytických zjištění

Analytická část práce se zaměřila na srovnání dvou nástrojů využitelných při humanitárním mapování, editoru JOSM a platformy fAIr. Porovnání bylo realizováno na základě metrik účinnosti a efektivity.

Výsledky ukázaly, že editor JOSM dosahuje statisticky významně vyšší efektivity i účinnosti ve srovnání s nástrojem fAIr. Tato zjištění byla podpořena výsledky Mann–

Whitneyho U testu, který potvrdil, že rozdíly v měřitelných výkonnostních parametrech nejsou náhodné. Zatímco JOSM umožňuje pokročilým uživatelům dosahovat vysoké přesnosti i v komplexních lokalitách díky detailnímu ovládání geometrie, nástroj fAIr vykazuje stabilnější tempo mapování, avšak za cenu nižší přesnosti, zejména v náročnějším terénu.

Důležitým aspektem bylo také hodnocení výkonnosti na základě zkušenosti uživatelů. Pokročilí mapéři dosahovali v JOSM nejlepších výsledků, zatímco začátečníci vykazovali srovnatelný nebo v některých případech i vyšší výkon ve fAIr, což lze přičíst nižší náročnosti jeho ovládání a omezené možnosti editace, která redukuje prostor pro chyby. fAIr tak působí jako inkluzivní nástroj vhodný pro méně zkušené uživatele, kteří mohou přispět do mapovacích projektů i bez hluboké znalosti GIS nástrojů.

Srovnání nástrojů dle náročnosti mapované oblasti ukázalo, že výkonnost JOSM zůstává relativně stabilní napříč různými geografickými podmínkami. Oproti tomu fAIr je více citlivý na kvalitu vstupních dat a komplexnost zástavby, což se negativně promítá do účinnosti výstupů v komplikovaných oblastech. Tento vývoj souvisí zejména s absencí post-processing algoritmů, které by umožnily korekci tvarů generovaných AI modelem.

Subjektivní zpětná vazba účastníků potvrzuje, že nástroj fAIr je vnímán jako vstřícnější díky jednoduchému rozhraní a automatickému generování objektů. Na druhé straně byl JOSM hodnocen jako nástroj s vyšší kontrolovatelností, ale s větší vstupní náročností, což jej činí vhodnějším pro zkušené mapéry. Někteří účastníci reflektovali možné kombinované využití obou nástrojů, například využít fAIr pro rychlé generování budov, poté exportovat výsledky do JOSM, kde by proběhla manuální kontrola a finální úpravy. Tento přístup by umožnil efektivní rozdělení práce, kdy by AI zajišťovala prvotní detekci objektů a editace by byla ponechána na lidském uživateli.

Celkově lze shrnout, že fAIr mapping je vnímán jako užitečný nástroj pro zrychlení mapování, ale jeho současná úroveň přesnosti neumožňuje jeho plnou integraci bez manuálních úprav. JOSM zůstává preferovaným nástrojem pro zkušené uživatele, kteří požadují větší kontrolu nad mapovacím procesem. Pro budoucí zlepšení AI nástrojů v humanitárním mapování by bylo vhodné zaměřit se na zvýšení přesnosti detekovaných objektů, rozšíření možností editace a jasné rozlišení AI generovaných dat od manuálních úprav. Z výsledků vyplývá, že plná automatizace mapování zatím není možná, avšak kombinace AI asistovaného mapování a manuální validace představuje realistickou cestu ke zvýšení efektivity v této oblasti.

7 DISKUSE

Výsledky této práce potvrdily, že výběr mapovacího nástroje má zásadní vliv na efektivitu a kvalitu humanitárního mapování, přičemž významnou roli hraje nejen technická specifikace nástroje, ale také úroveň zkušeností mapérů a charakteristika území. Skutečnost, že editace ve fAIr umožnila začátečníkům dosáhnout téměř stejných srovnatelných výsledků jako pokročilí uživatelé potvrzuje, že AI může výrazně snížit vstupní bariéry pro zapojení nových přispěvatelů, což je v souladu s cíli mnoha humanitárních mapovacích iniciativ. Tento trend byl pozorovaný v pilotních testech fAIr organizace HOT, kde se produktivita dobrovolníků při mapování budov zdvojnásobila již po prvních dvou hodinách práce (BRYANT, 2021). Podobný nárůst efektivy zaznamenala studie Mendes et al. (2021), která srovnávala mapathony s automatickou extrakcí a konstatovala téměř dvojnásobný počet nových prvků na OSM při zachování přesnosti. Zjištění tak naznačují, že kombinace AI asistence a manuální editace představuje potenciálně nejefektivnější přístup, jak vyvážit rychlost produkce dat s jejich přesností.

Současně se potvrdil náš závěr, že při mapování v komplexních oblastech zůstává přesnost ručního postupu v JOSM vyšší. Aby AI dokázala pomáhat i v komplexnějších oblastech, přišla fAIr s myšlenkou lokálního trénování modelů, kterou podporuje studie Sekara et al. Jejich výzkum poukázal, že globální modely detekce budov dosahují nižší skóre mapování v subsaharských podmínkách, oproti mapování po lokálním zaškolení. Nicméně nižší přesnost predikce a absence možnosti úprav ve fAIr jsou zatím dosavadním omezením pro použití mapování, kde je geometrická a topologická přesnost nevyhnutelná.

Zásadním přínosem této práce je empirické ověření toho, že AI není univerzálním řešením, ale spíše nástrojem, jehož přínos závisí na správné aplikaci a doplnění lidským úsudkem. Zkušenosti s editorem JOSM ukázaly, že přesnost výstupu lze významně zvýšit díky detailní kontrole, nicméně za cenu vyšší časové náročnosti a potřeby školení.

Budoucí výzkum by měl být zaměřen na optimalizaci AI modelů ve fAIr a jejich integraci s tradičními nástroji, jako je JOSM. Zlepšení podpory pro začátečníky a rozšíření komunitní spolupráce by mohlo zvýšit využitelnost obou nástrojů v různých kontextech.

Z pohledu krizového řízení a humanitární pomoci vyplývá, že optimální strategií může být využití AI nástroje pro počáteční fázi (např. rychlou lokalizaci osídlení), následovanou validací a doplněním dat v prostředí umožňujícím podrobnější editaci. Tento přístup

odpovídá praxi některých organizací (např. HOT nebo Lékaři bez hranic), které kombinují automatizované systémy s lidskou verifikací.

Omezením výzkumu byla zejména velikost vzorku, rozmanitost geografických oblastí a fáze vývoje nástroje fAIr. Je pravděpodobné, že s dalším vývojem predikčních modelů a zavedením post-processing funkcí dojde ke zlepšení přesnosti AI výstupů. Další výzkum by se měl zaměřit na možnosti propojení nástrojů fAIr a JOSM v rámci jednoho pracovního postupu, testování v různých krizových scénářích a zohlednění dalších typů mapovaných objektů, např. komunikací, vodních ploch nebo zdravotnických zařízení, které jsou důležité pro plánování humanitární pomoci.

ZÁVĚR

Diplomová práce se zaměřila na možnosti využití umělé inteligence při humanitárním mapování, zejména s ohledem na rostoucí potřebu rychlé a efektivní produkce geografických dat v oblastech postižených krizí. V teoretické části byly představeny základní principy fungování umělé inteligence v kontextu GIS a humanitárních operací, přičemž zvláštní pozornost byla věnována srovnání mezi globálními a lokálně trénovanými modely a jejich přínosu pro přesnost a adaptabilitu v terénu. Byly rovněž rozpracovány etické souvislosti využití AI v prostředí humanitární pomoci, které poukazují na potřebu transparentnosti, datové kvality a zapojení lokálních komunit.

V praktické části byla provedena experimentální evaluace nástroje fAIr, který reprezentuje novou generaci otevřených AI řešení v humanitárním mapování, ve srovnání s klasickým ručním mapováním v editoru JOSM. Z výsledků vyplynulo, že zatímco nástroj fAIr vykazuje potenciál pro efektivní zapojení méně zkušených uživatelů a může být vhodným doplňkem v méně náročných oblastech, editor JOSM dosahuje vyšší přesnosti i rychlosti mapování, především u zkušených uživatelů. Statistické vyhodnocení potvrdilo významné rozdíly v účinnosti i efektivitě mezi oběma přístupy, přičemž JOSM si vedl lépe ve všech sledovaných metrikách.

Výsledky experimentu zároveň ukázaly, že využití umělé inteligence ve formě nástroje fAIr může být cenným nástrojem zejména v případech, kdy je dostupnost mapérských kapacit omezená, nebo tam, kde je vhodné urychlit předvýběr objektů před samotnou editací. Výhodou fAIr je také možnost lokálního tréninku modelů, což zajišťuje lepší adaptaci na regionální podmínky a může napomoci k demokratizaci AI nástrojů v mapovacích procesech.

Na základě provedené analýzy lze konstatovat, že AI představuje významnou podporu pro rozvoj humanitárního mapování, avšak nikoliv náhradu za zkušené editory a validaci. Kombinace automatizovaných metod s lidskou expertízou se ukazuje jako nejvhodnější cesta pro budoucnost tohoto oboru. Další výzkum by měl směřovat k rozvoji uživatelsky přístupných nástrojů pro trénink modelů, k validaci výstupů a k větší integraci komunitních potřeb do vývoje těchto systémů.

SEZNAM POUŽITÉ LITERATURY

ABRAN, Alain; KHELIFI, Adel; SURYN, Witold a SEFFAH, Ahmed. *Usability Meanings and Interpretations in ISO Standards*, 2003. Online. s. 325-338. Dostupné z: <https://doi.org/https://doi.org/DOI:10.1023/A:1025869312943>. [cit. 2024-10-15].

BASU, Saikat; GILL, James; BONAFILIA, Derrick; KIRSANOV, Danil a YANG, David, 2019. *Mapping roads through deep learning and weakly supervised training*. Online. Dostupné z: <https://ai.meta.com/blog/mapping-roads-through-deep-learning-and-weakly-supervised-training/>. [cit. 2024-10-01].

BEDDOW, Christopher a TRIPATHI, Abhishek., 2023. *Rapid 2.0: Improving speed and efficiency in map editing*. Online. Dostupné z: <https://developers.facebook.com/blog/post/2023/04/04/rapid2/>. [cit. 2024-11-12].

BEDUSCHI, Ana. *Harnessing the potential of artificial intelligence for humanitarian action: Opportunities and risks*. Online. Dostupné z: <https://international-review.icrc.org/articles/harnessing-the-potential-of-artificial-intelligence-for-humanitarian-action-919>. [cit. 2024-08-24].

BRYANT, John, 2021. *Digital mapping and inclusion in humanitarian response*. HPG working paper. London: ODI (<https://odi.org/en/publications/digital-mapping-and-inclusion-in-humanitarian-response>).

CLARK, Ben. *Preview our next generation OSM editor: RapiD 2.0, 2022*. Online. Dostupné z: <https://developers.facebook.com/blog/post/2022/08/25/preview-our-next-generation-osm-editor-rapid-2-point-0/>. [cit. 2025-04-24].

ČSN EN ISO 9241-11, 2018. *Ergonomie interakce člověk-systém – Část 11: Využitelnost: Definice a koncepty*. Praha: Úřad pro technickou normalizaci, metrologii a státní zkušebnictví.

fAIr tutoriál. 2024. Interní studijní materiál. [Nepublikovaný dokument poskytnutý vedoucím práce].

FORBES, 2021. *Microsoft Is Now The World's Most Valuable Company After Apple Falls*. Online. Dostupné z: <https://www.forbes.com/sites/sergeiklebnikov/2021/10/29/microsoft-is-now-the-worlds-most-valuable-company-after-apple-falls-on-earnings/> [cit. 2024-10-01].

GAO, Xiaoming; KLAIBER, Christopher a UNDERWOOD, Jeff, 2019. *AI is supercharging the creation of maps around the world*. Online. Dostupné z: <https://tech.facebook.com/artificial-intelligence/2019/7/ai-is-supercharging-the-creation-of-maps-around-the-world/>. [cit. 2024-11-27].

GITHUB, 2020. CNTK. Online. Dostupné z: <https://github.com/microsoft/CNTK> [cit. 2024-11-10].

GITHUB, 2024. *fAIr AI-assisted Mapping*. Online. Dostupné z: <https://github.com/hotosm/fAI> [cit. 2024-11-23].

GOODCHILD, Michael, 2010. *Twenty years of progress: GIScience*. Online. Dostupné z: <https://doi.org/10.5311/JOSIS.2010.1.2>. [cit. 2024-11-11].

HAKLAY, Mordechai a WEBER, Patrick, 2008. *OpenStreetMap: User-Generated Street Maps*. Online. s. 12-18. Dostupné z: <https://doi.org/10.1109/MPRV.2008.80>. [cit. 2024-11-10].

HAKLAY, Mordechai, 2010. *How Good is Volunteered Geographical Information? A Comparative Study of OpenStreetMap and Ordnance Survey Datasets*. Online. Dostupné z: <https://doi.org/DOI: 10.1068/b35097>. [cit. 2024-10-24].

HOTOSM, 2024a. *Mikel Maron*. Online. Dostupné z: <https://www.hotosm.org/people/mikel-maron/> [cit. 2024-11-08].

HOTOSM, 2022b. *fAIr AI assisted mapping*. Online. Dostupné z: <https://www.hotosm.org/tech-blog/hot-tech-talks-fair/> [cit. 2024-11-08].

HOTOSM, 2024c. *What we do*. Online. Dostupné z: <https://www.hotosm.org/what-we-do> [cit. 2024-11-08].

HUMANITARIAN OPENSTREETMAP TEAM, 2022. *fAIr - AI Assisted Mapping Tool*. Online. Dostupné z: <https://github.com/hotosm/fAI> [cit. 2024-11-23].

HUMANITARIAN OPENSTREETMAP TEAM, 2024. *OpenAerialMap*. Online. Dostupné z: <https://www.hotosm.org/tech-suite/open-aerial-map/> [cit. 2025-04-23].

HUMANITARIAN OPENSTREETMAP TEAM, 2024. *What we do*. Online. Dostupné z: <https://www.hotosm.org/what-we-do> [cit. 2024-12-29].

INASAFE DOCUMENTATION, 2023. *Chapter 3: Introducing the iD Editor* Online. Dostupné z: <https://manual.inasafe.org/training/osm/Chapter-03-introducing-the-id-editor.html> [cit. 2024-11-23].

INTERNATIONAL COMMITTEE OF THE RED CROSS, 2024. *Handbook on Data Protection in Humanitarian Action*. 3. vydání. Geneva: ICRC Online. Dostupné z: <https://www.icrc.org/en/data-protection-humanitarian-action-handbook> [cit. 2024-11-23].

INVESTORS, 2025. *AI Stocks Face 'Show Me' Moment As Cloud Computing Giants Report Earnings*. Online. Dostupné z: <https://www.investors.com/news/technology/artificial-intelligence-stocks/> [cit. 2025-04-22].

JOSM, 2024a. *Plugins for JOSM*. Online. Dostupné z: <https://josm.openstreetmap.de/wiki/Plugins> [cit. 2024-11-20].

JOSM, 2024b. *Help/Preferences/Plugins*. Online. Dostupné z: <https://josm.openstreetmap.de/wiki/Help/Preferences/Plugins> [cit. 2024-11-20].

JOSM, 2024c. *Developing Plugins*. Online] Dostupné z: <https://josm.openstreetmap.de/wiki/DevelopersGuide/DevelopingPlugins> [cit. 2024-11-20].

JOSM tutoriál. 2024. Interní studijní materiál. [Nepublikovaný dokument poskytnutý vedoucím práce].

KAŠÍK, Daniel, 2022. *Vliv pandemické situace na mapathony a humanitární mapování*. Bakalářská práce. Brno: Masarykova Univerzita.

KLIMEŠ, Petr, 2023. *Využití budov předem vygenerovaných umělou inteligencí pro dobrovolnické mapování*. Diplomová práce. Brno: Masarykova univerzita.

LEARNOSM, 2019. *Beginner's Guide: iD Editor* Online. Dostupné z: <https://learnosm.org/en/beginner/id-editor/> [cit. 2024-11-23].

LINUX FOUNDATION, 2022. *Overture Maps Foundation to Build Interoperable Open Map Data*. Online. Dostupné z: <https://www.linuxfoundation.org/press/linux-foundation-announces-overture-maps-foundation-to-build-interoperable-open-map-data> [cit. 2024-12-11].

MA, Yuchi; CHEN, Shuo; ERMON, Stefano a LOBELL, David B., 2024. Transfer learning in environmental remote sensing. Online. *Remote Sensing of Environment*. Vol. 301. ISSN 00344257. Dostupné z: <https://doi.org/10.1016/j.rse.2023.113924>. [cit. 2025-04-24].

MENDES, Amalia; PALMER, Tess; BERENS, Andrew; ESPEY, Julie; PRICE, Rhiannan et al., 2021. *Mapathons versus automated feature extraction: a comparative analysis for strengthening immunization microplanning*. Online. International Journal of Health Geographics. vol. 20, č. 1. ISSN 1476-072X. Dostupné z: <https://doi.org/10.1186/s12942-021-00277-x>. [cit. 2025-04-24].

META, 2019. *How AI-powered maps help improve vaccination campaigns and rural electrification: Artificial Intelligence*. Online. Dostupné z: <https://tech.facebook.com/artificial-intelligence/2019/4/ai-powered-maps-help-vaccination-campaigns/>. [cit. 2024-11-20].

MICROSOFT, 2018. *AI for Earth: Helping save the planet with data science*. Online. Dostupné z: <https://news.microsoft.com/apac/2018/10/02/ai-for-earth-helping-save-the-planet-with-data-science/> [cit. 2024-10-02].

MICROSOFT, 2021. *Building Footprints* Online. Dostupné z: <https://www.microsoft.com/en-us/maps/building-footprints> [cit. 2024-11-06].

Microsoft Bing Blogs: *Facebook's Street Maps RapiD Editor Now Includes Microsoft Building Footprints*, 2020. Online. In: Dostupné z: <https://blogs.bing.com/maps/2020-03/facebooks-rapid-editor-now-includes-microsoft-building-footprints-e9626fa48a4ed1dcd7e36c5954964c95>. [cit. 2024-10-11].

NAJJAR, Omran, 2022. *Humanitarian OpenStreetMap Team | Hot_tech_talk | fAIr: AI-assisted mapping*. Online. Dostupné z: <https://www.hotosm.org/tech-blog/hot-tech-talks-fair/>. [cit. 2024-11-06].

NGUMENAWA, Samson, 2023. *HOT's Approach to OSM Data Validation for Earthquake Response Mapping*. HOT OSM Online. Dostupné z: <https://www.hotosm.org/updates/hot-approach-to-osm-data-validation-to-eq-mapping-projects/> [cit. 2024-11-23].

OBERMEYER, Ziad; EZEKIEL, J a , Emanuel, 2016. *Predicting the Future — Big Data, Machine Learning, and Clinical Medicine*. Online. Vol. 375. Dostupné z: <https://doi.org/10.1056/NEJMp1606181>. [cit. 2024-11-05].

OMDENA, 2022. *Enhancing Global Mapping Through AI: A Collaborative Initiative with Humanitarian OpenStreetMap Team and Omdena*. Online. Dostupné z: <https://www.omdena.com/projects/enhancing-global-mapping-through-ai-a-collaborative-initiative-with-humanitarian-openstreetmap-team-and-omdena> [cit. 2024-11-23].

OPENSTREETMAP WIKI CONTRIBUTORS, 2024: *Mapathon*. Online. Dostupné z: <https://en.wikipedia.org/wiki/Mapathon> [cit. 2024-12-30].

OPENSTREETMAP WIKI CONTRIBUTORS, 2024a. *Comparison of editors* Online. Dostupné z: https://wiki.openstreetmap.org/wiki/Comparison_of_editors [cit. 2024-12-30].

OPENSTREETMAP WIKI CONTRIBUTORS, 2024b. *JOSM* Online. Dostupné z: <https://wiki.openstreetmap.org/wiki/JOSM> [cit. 2024-12-30].

OVERTURE MAPS FOUNDATION, 2023. *Overture 2023-07-26-alpha.0. Release Notes* Online. Dostupné z: <https://overturemaps.org/download/overture-july-alpha-release-notes/> [cit. 2024-11-25].

OVERTURE MAPS FOUNDATION, 2024. *Become a Member*. Online. Dostupné z: <https://overturemaps.org/become-a-member/> [cit. 2024-12-11].

PIZZI, Michael; ROMANOFF, Mila a ENGELHARDT, Tim. AI for humanitarian action: Human rights and ethics. Online. *International Review of the Red Cross*. 2020, vol. 102, č. 913, s. 145-180. ISSN 1816-3831. Dostupné z: <https://doi.org/10.1017/S1816383121000011>. [cit. 2025-01-10].

QUINN, John A.; NYHAN, Marguerite M.; NAVARRO, Celia; COLUCCIA, Davide; BROMLEY, Lars et al., 2018. Humanitarian applications of machine learning with remote-sensing data: review and case study in refugee settlement mapping. Online. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*. vol. 376, č. 2128. ISSN 1364-503X. Dostupné z: <https://doi.org/10.1098/rsta.2017.0363>. [cit. 2025-04-25].

SECRET STACHE, 2023. *Between-Subjects vs. Within-Subjects studies* Online. Dostupné z: <https://www.secretstache.com/blog/between-subjects-within-subjects/> [cit. 2024-11-20]. 2021.

SEKARA, Vedran; MARTINI, Andrea; HERRANZ, Manuel Garzia a KIM, Do-Hyung, 2024. *Uncovering large inconsistencies between machine learning derived gridded settlement datasets*. Online. [cit. 2025-04-24].

SIRKO, Wojciech; KASHUBIN, Sergii; RITTER, Marvin; ANNKAH, Abigail; BOUCHAREB, Yasser Salah Edine et al., 2021. *Continental-Scale Building Detection from High Resolution Satellite Imagery*. Online. Dostupné z: <https://doi.org/10.48550/arXiv.2107.12283>. [cit. 2024-04-20].

TECHCRUNCH, 2022. *Meta, Microsoft, AWS and TomTom launch the Overture Maps Foundation*. Online. Dostupné z: <https://techcrunch.com/2022/12/15/meta-microsoft-aws-and-tomtom-launch-the-overture-maps-foundation-to-develop-interoperable-open-map-data/> [cit. 2024-12-11].

TOMŠŮ, Jan, 2023. *Využití cest předem vygenerovaných umělou inteligencí pro dobrovolnické mapování*. Diplomová práce. Brno: Masarykova Univerzita.

TOMTOM, 2022. *TomTom, Amazon Web Services, Meta and Microsoft join forces and launch open map data foundation*. Online. Dostupné z: <https://www.tomtom.com/newsroom/behind-the-map/the-overture-foundation-and-its-tech/> [cit. 2024-12-11].

TULANE UNIVERSITY, 2023. *Developing a Disaster Communication Plan: 8 Steps*. Online. Dostupné z: <https://publichealth.tulane.edu/blog/developing-disaster-communication-plan/> [cit. 2024-11-23].

ZHOU, Lichen; ZHANG, Chuang a WU, Ming, 2018. D-LinkNet: LinkNet with Pretrained Encoder and Dilated Convolution for High Resolution Satellite Imagery Road Extraction. Online. *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. s. 192-1924. ISBN 978-1-5386-6100-0. Dostupné z: <https://doi.org/10.1109/CVPRW.2018.00034>. [cit. 2024-10-20]

ZHU, Xiao Xiang; TUIA, Devis; MOU, Lichao; XIA, Gui-Song; ZHANG, Liangpei et al., 2017. Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources. Online. *IEEE Geoscience and Remote Sensing Magazine*. vol. 5, č. 4, s. 8-36. ISSN 2168-6831. Dostupné z: <https://doi.org/10.1109/MGRS.2017.2762307>. [cit. 2024-10-2020].

ZOOK, Matthew; GRAHAM, Mark; SHELTON, Taylor a GORMAN, Sean, 2010. Volunteered Geographic Information and Crowdsourcing Disaster Relief: A Case Study of the Haitian Earthquake. Online. vol. 2, č. 2, č. 7-33. ISSN 1948-4682. Dostupné z: <https://doi.org/10.2202/1948-4682.1069>. [cit. 2024-10-25].

SEZNAM OBRÁZKŮ

Obrázek 1. Úvodní stránka fAIr	38
Obrázek 2. Výběr AI modelových úloh.....	39
Obrázek 3. Trénovací oblast pro AI.....	39
Obrázek 4. Testování generovaných objektů.....	41
Obrázek 5. Konfigurační okno s výchozími hodnotami,	42
Obrázek 6 Předvolby v programu JOSM.....	46
Obrázek 7 Ukázka jednoduché lokality Kamerun	54
Obrázek 8 Ukázka komplexní lokality Monrovia.....	54
Obrázek 9 otevřený dotazník	75
Obrázek 10 uzavřený dotazník k chybějícím instrukcím.....	75
Obrázek 11 uzavřený dotazník o využití fAIr při mapování	76
Obrázek 12 uzavřený dotazník pro preferovaný nástroj	77

SEZNAM TABULEK

Tabulka 1 Profil participantů	53
Tabulka 2 porovnání efektivity mezi vybranými nástroji	65
Tabulka 3 porovnání účinnosti mezi vybranými nástroji.....	65
Tabulka 4 Srovnání efektivity a účinnosti v JOSM podle úrovně zkušenosti uživatele.....	66
Tabulka 5 Srovnání efektivity a účinnosti v fAIr podle úrovně zkušenosti uživatele	67
Tabulka 6 výsledky dle náročnosti oblasti v fAIr	68
Tabulka 7 výsledky dle náročnosti oblasti v JOSM.....	68
Tabulka 8 rozdělení normality pro testované nástroje	69
Tabulka 9 statistické testování obou nástrojů	70
Tabulka 10 rozdělení normality účinnosti začátečníků podle Shapiro-Wilkova testu.....	71
Tabulka 11 rozdělení normality účinnosti zkušených účastníků podle Shapiro-Wilkova testu	71
Tabulka 12 rozdělení normality efektivity zkušených uživatelů podle Shapiro-Wilkova testu	72
Tabulka 13 Počet účastníků, u kterých byl zjištěn daný typ chyby při mapování ve fAIr ..	73

SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

AI	Artificial Intelligence (umělá inteligence)
CNN	Convolutional Neural Network (konvoluční neuronová síť)
CNTK	Microsoft Cognitive Toolkit (deep learning framework)
CSV	Comma Separated Values (formát tabulkových dat)
GeoJSON	Geospatial JavaScript Object Notation (formát prostorových dat)
GIS	Geographic Information Systems (geografické informační systémy)
HOT	Humanitarian OpenStreetMap Team
JOSM	Java OpenStreetMap (desktopový editor OSM)
JSON	JavaScript Object Notation (formát pro datové struktury)
ML	Machine Learning (strojové učení)
OAM	Open Aerial Map (platforma pro letecké snímky)
OSM	OpenStreetMap (otevřená mapa)
POI	Point of Interest (bod zájmu)
QGIS	Quantum Geographic Information System (open-source GIS software)
RapiD	AI rozšířený editor OSM (Meta)
ResNet34	Residual Neural Network (CNN architektura)
SAM	Segment Anything Model (model pro segmentaci)
TMS	Tile Map Service (zobrazování mapových dlaždic)
UAV	Unmanned Aerial Vehicle (bezpilotní letecký prostředek)
WMTS	Web Map Tile Service (standard pro mapové dlaždice)
WMS	Web Map Service (služba poskytující mapy)

SEZNAM PŘÍLOH

PŘÍLOHA P I: NÁZEV PRVNÍ PŘÍLOHY